



TESIS - SS142501

***BAYESIAN MODEL AVERAGING DAN
GEOSTATISTICAL OUTPUT PERTURBATION
UNTUK PRAKIRAAN CUACA JANGKA PENDEK
TERKALIBRASI***

MUHAMMAD LUTHFI SETIARNO PUTERA
NRP. 1315201203

DOSEN PEMBIMBING
Dr. Sutikno, M.Si
Dr. Purhadi, M.Sc

PROGRAM MAGISTER
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2017



TESIS - SS142501

***BAYESIAN MODEL AVERAGING DAN
GEOSTATISTICAL OUTPUT PERTURBATION
UNTUK PRAKIRAAN CUACA JANGKA PENDEK
TERKALIBRASI***

MUHAMMAD LUTHFI SETIARNO PUTERA
NRP. 1315201203

DOSEN PEMBIMBING
Dr. Sutikno, M.Si
Dr. Purhadi, M.Sc

PROGRAM MAGISTER
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2017



THESIS - SS142501

BAYESIAN MODEL AVERAGING AND GEOSTATISTICAL OUTPUT PERTURBATION TO CALIBRATE SHORT-RANGE WEATHER FORECAST

MUHAMMAD LUTHFI SETIARNO PUTERA
NRP. 1315201203

SUPERVISORS

Dr. Sutikno, M.Si

Dr. Purhadi, M.Sc

MAGISTER PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS AND NATURAL SCIENCES
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2017

**BAYESIAN MODEL AVERAGING DAN GEOSTATISTICAL OUTPUT
PERTURBATION UNTUK PRAKIRAAN CUACA
JANGKA PENDEK TERKALIBRASI**

Tesis ini disusun untuk memenuhi salah satu syarat memperoleh gelar

Magister Sains (M.Si)

di

Institut Teknologi Sepuluh Nopember

oleh :

MUHAMMAD LUTHI SETIARNOPUTERA

NRP. 1315201203

Tanggal Ujian : 20 Juni 2017

Periode Wisuda : September 2017

Disetujui oleh :

1. **Dr. Sutikno, M.Si**
NIP. 19710313 199702 1 001

(Pembimbing I)

2. **Dr. Purnadi, M.Sc**
NIP. 19620204 198701 1 001

(Pembimbing II)

3. **Santi Wulan P., M.Si., Ph.D**
NIP. 19720923 199803 2 001

(Penguji I)

4. **Prof. Nur Iriawan, M.Komp, Ph.D**
NIP. 19621015 198803 1 002

(Penguji II)

Dekan

Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember

Prof. Dr. Basuki Widodo, M.Sc
NIP. 19650605 198903 1 002

BAYESIAN MODEL AVERAGING DAN GEOSTATISTICAL OUTPUT PERTURBATION UNTUK PRAKIRAAN CUACA JANGKA PENDEK TERKALIBRASI

Nama Mahasiswa : Muhammad Luthfi SP
NRP : 1315201203
Dosen Pembimbing : Dr. Sutikno, M.Si
Dr. Purhadi, M.Sc

ABSTRAK

Data prakiraan cuaca berbasis numerik, *Numerical Weather Prediction* (NWP), yang selama ini digunakan untuk membantu para *forecaster* masih belum mampu untuk menghasilkan prakiraan cuaca dengan akurat, termasuk untuk jangka pendek. Ensemble adalah gabungan beberapa metode prakiraan yang bertujuan untuk memperbaiki akurasi dan presisi prakiraan. Namun, ensemble seringkali masih bersifat *underdispersive*, yaitu prakiraan cuaca cenderung terpusat pada suatu nilai dengan varians yang rendah. *Bayesian Model Averaging* (BMA) adalah metode parametrik untuk mengkalibrasi prakiraan ensemble dan membentuk interval prediktif yang lebih reliabel. Namun, BMA tidak mempertimbangkan korelasi spasial dalam menghasilkan prakiraan cuaca terkalibrasi. Selain itu, beberapa parameter BMA tidak dapat diestimasi secara analitik dengan MLE. Tidak seperti BMA, *Geostatistical Output Perturbation* (GOP) mempertimbangkan korelasi spasial seluruh lokasi secara serentak. GOP memiliki parameter spasial yang berfungsi untuk memodifikasi hasil prakiraan cuaca sedemikian hingga mampu memanfaatkan informasi spasial. Suhu udara menjadi fokus penelitian karena memiliki hubungan yang cukup erat dengan elemen cuaca lainnya. Analisis yang digunakan untuk mengkalibrasi prakiraan suhu udara di delapan stasiun meteorologi Jabotabek adalah BMA dan GOP. Tahap awal dilakukan reduksi dimensi untuk tiap parameter NWP menggunakan *Principal Component Analysis* (PCA), sehingga prediktor untuk BMA adalah skor komponen utama sementara prediktor GOP adalah luaran NWP pada grid yang bersesuaian dengan stamet. Ensemble terdiri dari tiga metode statistik, yaitu regresi PLS, PCR, dan Ridge. Untuk periode training selama 30 hari, prakiraan suhu udara BMA di 8 stamet termasuk ke dalam kriteria baik-sedang. BMA juga mampu mengkalibrasi prakiraan suhu udara dimana *coverage* yang dihasilkan sudah mendekati standar 50%. Sementara, GOP masih menghasilkan prakiraan dengan bias yang cukup tinggi, bahkan tidak terkalibrasi karena *coverage* 75% yang masih bersifat *underdispersive*. Namun, jika pemodelan GOP tidak melibatkan stamet Citeko, maka akurasi dan presisi prakiraan menjadi lebih tinggi. Dapat disimpulkan bahwa akurasi dan presisi prakiraan BMA lebih tinggi daripada GOP.

Kata Kunci : BMA, Ensemble, GOP, NWP, *Underdispersive*

(Halaman ini sengaja dikosongkan)

BAYESIAN MODEL AVERAGING AND GEOSTATISTICAL OUTPUT PERTURBATION TO CALIBRATE SHORT-RANGE WEATHER FORECAST

Name : Muhammad Luthfi SP
Registration Number : 1315201203
Supervisors : Dr. Sutikno, M.Si
Dr. Purhadi, M.Sc

ABSTRACT

Massive Numerical Weather Prediction (NWP) currently utilized to aid the forecasters has not yet been able to produce the weather forecast accurately, including for the short-range one. Ensemble is a combination of several processing methods to improve the accuracy and precision. However, it still possesses underdispersive nature, that is the forecast tends to concentrate at a point with low variance. Bayesian Model Averaging (BMA) is parametric method to calibrate the ensemble prediction and create more reliable predictive interval. BMA producing the calibrated forecast, though, does not consider spatial correlation. Furthermore, some BMA parameters are not able to be estimated by MLE. Unlike BMA, Geostatistical Output Perturbation (GOP) reckons spatial correlation among many locations altogether. It owns spatial parameters modifying the forecast output such that being able to capture spatial information. Temperature being the interest tends to have relatively strong correlation with the other elements. Analysis applied to calibrate the temperature forecast at eight meteorological sites within Jabotabek are BMA and GOP. Firstly, dimension reduction of each NWP parameter is applied by Principal Component Analysis, after which BMA's predictors are PC scores while GOP's ones are NWP output of temperature at nearest grid corresponding to the interest site. The ensemble members consist of prediction of PLS, PCR, and Ridge regression. For training period over 30 days, BMA temperature forecasts at 8 sites classify into good and fair ones. It is able to calibrate the temperature forecast as well, of which the coverage comes closer to the standard 50%. Meanwhile, GOP yet produces the forecasts possessing quite high bias, even uncalibrated due to underdispersive nature indicated by the 75% coverage, less than the standard 90%. The accuracy and precision somehow improve quite significant without involving Citeko site. Based on some common assessment indicators of weather forecast, such as RMSE and CRPS, BMA is better than GOP in terms of accuracy and precision.

Keywords : BMA, Ensemble, GOP, NWP, Underdispersive

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Segala puji bagi Allah yang telah memberikan petunjuk, kemudahan, kelancaran, dan kekuatan kepada penulis, sehingga dapat menyelesaikan buku Tesis dengan judul “***BAYESIAN MODEL AVERAGING DAN GEOSTATISTICAL OUTPUT PERTURBATION UNTUK PRAKIRAAN CUACA JANGKA PENDEK TERKALIBRASI***” dengan baik.

Penulis menyadari bahwa dalam penyusunan Tesis ini tidak terlepas dari bimbingan dan dukungan dari berbagai pihak. Oleh karena itu, penulis mengucapkan terima kasih banyak kepada :

1. Kedua orang tua penulis dan kakak yang selalu mendoakan kesuksesan penulis dan mendorong untuk terus semangat sehingga dapat terus menebalkan keteguhan penulis dalam menyelesaikan Tesis.
2. Bapak Dr. Sutikno, M.Si dan Bapak Dr. Purhadi, M.Sc selaku dosen pembimbing yang telah membagikan ilmu, nasehat, saran, dan waktu yang diluangkan untuk membimbing penulis dalam menyusun Tesis.
3. Ibu Santi Wulan P, M.Si., Ph.D dan Bapak Prof. Nur Iriawan, Mkom, Ph.D selaku dosen penguji yang telah memberikan saran dan kritik yang membangun dalam penyusunan Tesis.
4. Bapak Dr. Suhartono, M.Sc selaku Kepala Departemen Statistika ITS, seluruh tenaga pengajar yang telah membagikan ilmu yang bermanfaat pada penulis, dan seluruh karyawan Tata Usaha dan Ruang Baca Statistika.
5. Bapak Dr.rer.pol. Heri Kuswanto, M.Si selaku Ketua Program Studi Pascasarjana Departemen Statistika ITS.
6. Ibu Dr. Vita Ratnasari, M.Si selaku dosen wali yang telah mengarahkan dan memberikan penulis nasehat akademik.

7. Teman-teman seperjuangan di Pascasarjana S2 Statistika 2015, baik Batch Ganjil 2015 dan Batch Genap 2015 (Mas Rama, Samsul, Jaya, Alm. Ismail, Mbak Amel, Mbak Halwa, Mbak Titis, Mbak Ribka, Ayya, Nisa, Chusnul, Fani) atas kebersamaannya.
8. Pihak-pihak lain yang telah mendukung, diantaranya BMKG dan Kemenristekdikti, terselesaikannya Tesis ini.

Mengingat keterbatasan penulis, maka penulis merasa masih banyak kekurangan, baik pada teknis penulisan maupun materi. Oleh karena itu, penulis mengharapkan kritik dan saran dari pembaca agar ke depannya lebih baik. Semoga buku Tesis ini dapat bermanfaat bagi kita semua. Amin.

Surabaya, Juli 2017

Penulis

DAFTAR ISI

LEMBAR PENGESAHAN	i
ABSTRAK	iii
ABSTRACT	v
KATA PENGANTAR	vii
DAFTAR ISI	ix
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xv
DAFTAR LAMPIRAN	xvii
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Tujuan Penelitian	6
1.4 Manfaat Penelitian	6
1.5 Batasan Masalah	6
BAB 2 TINJAUAN PUSTAKA	7
2.1 Distribusi Normal	7
2.1.1 Distribusi Normal Univariat	7
2.1.2 Distribusi Normal Multivariat	7
2.2 <i>Principal Component Analysis</i> (PCA)	8
2.3 <i>Partial Least Squares</i> (PLS)	10
2.4 <i>Principal Component Regression</i> (PCR)	13
2.5 Regresi Ridge	14
2.6 <i>Bayesian Model Averaging</i> (BMA)	15
2.7 <i>Geostatistical Output Perturbation</i> (GOP)	20
2.8 Dependensi Spasial	23
2.9 Evaluasi Kebaikan Model Kalibrasi	24
2.9.1 <i>Root Mean Square Error</i> (RMSE)	25

2.9.2 Coverage	25
2.9.3 Continuous Rank Probability Score (CRPS)	26
2.9 Numerical Weather Prediction (NWP)	27
2.10 Sistem Prediksi Ensemble	30
2.11 Suhu / Temperatur	32
BAB 3 METODE PENELITIAN	33
3.1 Sumber Data	33
3.2 Variabel Penelitian	34
3.3 Kajian Teoritis	38
3.4 Kajian Aplikasi.....	40
BAB 4 HASIL DAN PEMBAHASAN	45
4.1 Penaksiran Parameter BMA	45
4.1.1 Estimasi Parameter Regresi	45
4.1.2 Estimasi Parameter Bobot dan Varians	48
4.2 Penaksiran Parameter GOP	55
4.3 Aplikasi BMA dan GOP untuk Prakiraan Cuaca Jangka Pendek Terkalibrasi di 8 Stasiun Meteorologi Jabodetabek ...	59
4.3.1 Analisis Deskripsi Suhu Udara dan Standardisasi	59
4.3.2 Pra-pemrosesan Parameter NWP dengan PCA	61
4.3.3 Pembentukan Model Prakiraan Anggota Ensemble untuk Suhu Maksimum dan Suhu Minimum	63
4.3.3.1 Regresi PLS untuk Suhu Maksimum dan Suhu Minimum	64
4.3.3.2 Regresi PCR untuk Suhu Maksimum dan Suhu Minimum	69
4.3.3.3 Regresi Ridge untuk Suhu Maksimum dan Suhu Minimum	73
4.3.4 Deskripsi Prakiraan Cuaca Anggota Ensemble.....	76
4.3.5 Kalibrasi Prakiraan Cuaca Menggunakan BMA.....	78

4.3.6 Prakiraan Cuaca Berbasis Spasial Menggunakan GOP	85
4.3.7 Evaluasi Prakiraan BMA dan GOP	93
BAB 5 KESIMPULAN DAN SARAN	95
5.1 Kesimpulan	95
5.2 Saran	96
DAFTAR PUSTAKA	97
LAMPIRAN.....	101

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

Tabel 3.1	Parameter NWP CCAM yang Digunakan	34
Tabel 3.2	Struktur Data untuk Metode BMA pada Stasiun s.....	37
Tabel 3.3	Struktur Data untuk Metode GOP pada Stasiun s.....	38
Tabel 4.1	Nilai Eigen dan Kumulatif Varians (%) PC Variabel Presipitasi (rnd).....	61
Tabel 4.2	Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Dermaga	62
Tabel 4.3	Nilai PRESS Model PLS Stamet Dermaga.....	64
Tabel 4.4	Jumlah Komponen Optimal Model PLS pada Delapan Stasiun.....	65
Tabel 4.5	Koefisien Regresi Model PLS Stamet Dermaga.....	67
Tabel 4.6	Model PLS untuk Prakiraan Cuaca Stamet Dermaga	68
Tabel 4.7	Kumulatif Varians 41 Komponen Prediktor Stamet Dermaga	70
Tabel 4.8	Jumlah Komponen Optimal PCR pada Delapan Stasiun	70
Tabel 4.9	Koefisien Regresi Model PCR Stamet Dermaga	71
Tabel 4.10	Model PCR untuk Prakiraan Cuaca Stamet Dermaga	72
Tabel 4.11	Koefisien Regresi Ridge Stamet Dermaga	74
Tabel 4.12	Model Regresi Ridge untuk Prakiraan Cuaca Stamet Dermaga.....	75
Tabel 4.13	Estimasi Parameter BMA untuk 14 November 2009 di Stamet Dermaga.....	82
Tabel 4.14	Perbandingan Keباikan Prakiraan BMA dan Ensemble pada Stamet Dermaga, 31 Jan '09 – 31 Des '10.....	84
Tabel 4.15	Matrik Jarak 8 Stasiun Meteorologi Jabotabek.....	86
Tabel 4.16	Signifikansi Moran's I pada Observasi Cuaca di 8 Stamet..	86
Tabel 4.17	Estimasi Parameter Regresi Model GOP, 1 Jan'09 – 30 Jan '09	88

Tabel 4.18 RMSE Prakiraan GOP dan NWP untuk 8 Stamet, 31 Jan '09	90
Tabel 4.19 Estimasi Parameter Regresi Model GOP tanpa Stamet Citeko, 1 Jan '09 – 30 Jan '09	91
Tabel 4.20 Perbandingan Indikator Kebaikan Model GOP, 31 Jan '09-31 Des '10.....	92
Tabel 4.21 Evaluasi Prakiraan NWP, <i>Raw Ensemble</i> dan BMA untuk 8 Stamet.....	94

DAFTAR GAMBAR

Gambar 2.1	Semivariogram Pra-Simulasi GOP.....	22
Gambar 2.2	CDF Observasi dan Prakiraan pada Waktu ke- i	27
Gambar 2.3	Ilustrasi Kondisi Cuaca Dunia Nyata dan NWP	29
Gambar 2.4	Prediksi 2 Model Ensemble untuk Temperatur Wilayah Jerman 5 Januari 2011	32
Gambar 3.1	Lokasi Stasiun Meteorologi	33
Gambar 3.2	Proyeksi Pengukuran NWP.....	35
Gambar 3.3	Tahapan Analisis Data	43
Gambar 4.1	Observasi Suhu Maksimum dan Suhu Minimum di Stamet Dermaga.....	60
Gambar 4.2	Konvergensi Koefisien Regresi Ridge	73
Gambar 4.3	Tren Prakiraan Anggota Ensemble dan Observasi Suhu Maksimum	76
Gambar 4.4	Tren Prakiraan Anggota Ensemble dan Observasi Suhu Minimum	77
Gambar 4.5	Korelasi Ensemble Range terhadap Error Prakiraan, 1 Jan '09 – 30 Jan '09	79
Gambar 4.6	VRH <i>Raw Ensemble</i> Stamet Dermaga, 1 Jan '09 – 30 Jan '09	80
Gambar 4.7	Ilustrasi <i>Windowing</i> pada BMA	81
Gambar 4.8	PDF Prediktif BMA Stamet Dermaga, 14 November 2009..	83
Gambar 4.9	VRH BMA Stamet Dermaga, 31 Jan '09 – 31 Des '10	84
Gambar 4.10	Tahapan GOP	85
Gambar 4.11	Moran Scatterplot.....	87
Gambar 4.12	Semivariogram Empiris Suhu Udara, 1 Jan '09 – 30 Jan '09.....	89
Gambar 4.13	Semivariogram Empiris Suhu Udara tanpa Citeko, 1 Jan '09 – 30 Jan '09.....	92

Gambar 4.14 Prakiraan BMA, GOP dan Observasi Suhu Udara

Stamet Dermaga 93

DAFTAR LAMPIRAN

Lampiran 1. Rata-rata dan Standar Deviasi Variabel Respon.....	101
Lampiran 2. Rata-rata dan Standar Deviasi Parameter NWP Stamet Kemayoran.....	101
Lampiran 3. Rata-rata dan Standar Deviasi Parameter NWP Stamet Priok.....	102
Lampiran 4. Rata-rata dan Standar Deviasi Parameter NWP Stamet Cengkareng	102
Lampiran 5. Rata-rata dan Standar Deviasi Parameter NWP Stamet Pondok Betung.....	103
Lampiran 6. Rata-rata dan Standar Deviasi Parameter NWP Stamet Curug	103
Lampiran 7. Rata-rata dan Standar Deviasi Parameter NWP Stamet Tangerang	104
Lampiran 8. Rata-rata dan Standar Deviasi Parameter NWP Stamet Citeko.....	104
Lampiran 9. Rata-rata dan Standar Deviasi Parameter NWP Stamet Dermaga.....	105
Lampiran 10. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Kemayoran	105
Lampiran 11. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Priok	106
Lampiran 12. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Cengkareng.....	106
Lampiran 13. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Pondok Betung	107
Lampiran 14. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Curug.....	107

Lampiran 15. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Tangerang	108
Lampiran 16. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Citeko	108
Lampiran 17. Nilai PRESS Model PLS Stamet Kemayoran	109
Lampiran 18. Nilai PRESS Model PLS Stamet Priok	110
Lampiran 19. Nilai PRESS Model PLS Stamet Cengkareng	110
Lampiran 20. Nilai PRESS Model PLS Stamet Pondok Betung	111
Lampiran 21. Nilai PRESS Model PLS Stamet Curug.....	112
Lampiran 22. Nilai PRESS Model PLS Stamet Tangerang.....	112
Lampiran 23. Nilai PRESS Model PLS Stamet Citeko	113
Lampiran 24. Model Regresi PLS Stamet Dermaga.....	114
Lampiran 25. Prakiraan Suhu Maksimum Model PLS.....	115
Lampiran 26. Prakiraan Suhu Minimum Model PLS	116
Lampiran 27. Kumulatif Varians Komponen Prediktor Stamet Kemayoran	117
Lampiran 28. Kumulatif Varians Komponen Prediktor Stamet Priok....	117
Lampiran 29. Kumulatif Varians Komponen Prediktor Stamet Cengkareng	117
Lampiran 30. Kumulatif Varians Komponen Prediktor Stamet Pondok Betung	118
Lampiran 31. Kumulatif Varians Komponen Prediktor Stamet Curug ..	118
Lampiran 32. Kumulatif Varians Komponen Prediktor Stamet Tangerang.....	118
Lampiran 33. Kumulatif Varians Komponen Prediktor Stamet Citeko..	119
Lampiran 34. Model PCR untuk Prakiraan Cuaca Stamet Dermaga.....	119
Lampiran 35. Prakiraan Suhu Maksimum Model PCR	120
Lampiran 36. Prakiraan Suhu Minimum Model PCR	121
Lampiran 37. Konstanta λ Terpilih untuk Regresi Ridge	122
Lampiran 38. Model Ridge untuk Prakiraan Cuaca Stamet Dermaga....	123
Lampiran 39. Prakiraan Suhu Maksimum Model Ridge	124

Lampiran 40. Prakiraan Suhu Minimum Model Ridge.....	125
Lampiran 41. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet Cengkareng dan Citeko, Suhu Maksimum.....	126
Lampiran 42. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet Curug dan Dermaga, Suhu Maksimum.....	127
Lampiran 43. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet Kemayoran dan Pondok Betung, Suhu Maksimum.....	128
Lampiran 44. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet Tangerang dan Priok, Suhu Maksimum.....	129
Lampiran 45. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet Cengkareng dan Citeko, Suhu Minimum.....	130
Lampiran 46. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet Curug dan Dermaga, Suhu Minimum	131
Lampiran 47. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet Kemayoran dan Pondok Betung, Suhu Minimum	132
Lampiran 48. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet Tangerang dan Priok, Suhu Minimum	133
Lampiran 49. Prakiraan Suhu Maksimum BMA	134
Lampiran 50. Prakiraan Suhu Minimum BMA	135
Lampiran 51. Prakiraan Suhu Maksimum GOP	136
Lampiran 52. Prakiraan Suhu Minimum GOP.....	137
Lampiran 53. Indikator Kebaikan Prakiraan Tiap 8 Stamet untuk Training 30 Hari	138
Lampiran 54. Kriteria Prakiraan Cuaca Berdasarkan RMSE	139
Lampiran 55. Syntax Program	140

(Halaman ini sengaja dikosongkan)

BAB I

PENDAHULUAN

1.1 Latar Belakang

Informasi tentang prakiraan cuaca yang cepat dan akurat menjadi suatu hal yang vital, karena kondisi cuaca berpengaruh terhadap kelancaran aktivitas manusia, seperti penentuan masa tanam-panen (pertanian), penentuan periode/waktu penangkapan hasil laut (perikanan), dan penentuan kelayakan penerbangan atau pelayaran (perhubungan-transportasi). Indonesia memiliki karakteristik cuaca yang unik sebab berada di antara Samudera Pasifik dan Samudera Hindia. Selain itu, Indonesia adalah negara beriklim mosun dengan dinamika cuaca dan atmosfer yang berperan dominan dalam sistem cuaca dan iklim global (Tjasyono dan Harijono, 2008). Oleh sebab itu, pengolahan informasi peramalan cuaca dalam jangka pendek, menengah dan panjang terus dilakukan untuk mengetahui metode yang lebih tepat dalam menangkap karakteristik cuaca di masing-masing daerah.

Selama ini, kondisi cuaca di Indonesia diumumkan oleh Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) melalui hasil analisis prakiraan cuaca untuk jangka waktu 24 jam. Namun, metode prakiraan cuaca yang digunakan BMKG cenderung subjektif, karena masih mengandalkan kemampuan para *forecaster*. Kendala ini didukung oleh hasil verifikasi Bidang Analisa Meteorologi tahun 2004 dimana prakiraan *forecaster*, khususnya untuk parameter suhu maksimum, suhu minimum, dan kelembapan relatif, belum memenuhi ekspektasi (BMKG, 2011). Untuk meningkatkan akurasi prakiraan, BMKG berupaya mengembangkan peramalan cuaca secara numerik, diantaranya menggunakan model *Numerical Weather Prediction* (NWP) yang diolah sistem informasi tertentu dan menghasilkan luaran (*output*) yang bersifat deterministik.

Namun, prakiraan cuaca yang dihasilkan NWP tidak reliabel. Hal ini disebabkan ramalan NWP umumnya memberikan informasi cuaca yang bersifat homogen dan diukur pada skala global (Wilks, 2006). Hal ini bertentangan dengan fakta bahwa Indonesia ditutupi oleh vegetasi yang kompleks dengan topografi yang beragam. Selain itu, kelemahan NWP adalah tidak mampu

menangkap kondisi atmosfer yang berfluktuasi dan terbatasnya perhitungan matematis dan fisis yang digunakan untuk meramalkan cuaca (Idowu dan Rautenbach, 2009). Untuk meningkatkan akurasi prakiraan, dilakukan pemrosesan secara statistik (*statistical post-processing*) terhadap luaran NWP dengan pemrosesan ensemble.

Ensemble memproses luaran NWP dengan menggabungkan beberapa metode individual (regresi *stepwise*, regresi komponen utama, ARIMA dan sebagainya), metode *hybrid* (ARIMA-ANN, Wavelet-ANFIS, dan sebagainya). Selain itu, pendekatan ini juga dapat menerapkan spesifikasi model dengan syarat inisiasi yang berbeda disesuaikan dengan kondisi atmosfer atau menggunakan sejumlah luaran NWP yang dikeluarkan oleh beberapa otoritas resmi. Hingga saat ini, terdapat banyak institusi atau otoritas negara maju yang menggunakan sistem prakiraan ensemble.

Meskipun kemampuan prakiraan yang dihasilkan relatif baik, namun didapati bahwa prakiraan ensemble untuk jangka menengah masih bersifat *underdispersive* atau *overdispersive*, sehingga diperlukan kalibrasi prakiraan ensemble untuk mengatasi hal tersebut (Schmeits dan Kok, 2010). Kasus *underdispersive* dapat dimaknai sebagai kecenderungan terpusatnya nilai prakiraan cuaca pada suatu interval dengan varians yang rendah. Berbanding terbalik dengan *overdispersive* dimana prakiraan cuaca justru cenderung terpusat pada suatu interval dengan varians yang tinggi.

Beberapa metode untuk mengkalibrasi prakiraan ensemble adalah regresi logistik (Wilks, 2006), *Bayesian Model Averaging* (BMA) (Raftery, Gneiting, Balabdaoui, dan Polakowski, 2005), dan *Ensemble Model Output Statistics* (EMOS) (Gneiting, Raftery, Westveld III, dan Goldman, 2005). Metode-metode tersebut memadukan seluruh anggota ensemble, sehingga diperoleh suatu fungsi padat probabilitas (PDF) prediktif untuk mendapatkan prakiraan cuaca beberapa waktu ke depan (Devin, Clarke, Roulston, Ziehmann, Bocker, dan Smith, 2004). Penerapan beberapa metode tersebut disesuaikan dengan karakteristik komponen cuaca yang ingin dikalibrasi, apakah mengikuti distribusi normal, Gamma, dan sebagainya.

BMA adalah metode yang memadukan prakiraan/ramalan seluruh anggota ensemble berdasarkan rata-rata terboboti, probabilitas posterior anggota ensemble, sehingga tidak hanya mempertimbangkan kontribusi salah satu model saja seperti sebagian besar pemodelan statistika. Parameter BMA dapat dibedakan ke dalam 2 bagian, yaitu parameter regresi serta parameter bobot dan varians. Pada umumnya, parameter tersebut diestimasi dengan metode *Maximum Likelihood Estimation* (MLE). Namun, fungsi *joint likelihood* dari bobot dan varians tidak dapat diselesaikan secara analitik, sehingga digunakan algoritma *Expectation-Maximization* (EM) untuk mendapatkan penaksir parameternya. Kemudian, estimator-estimator tersebut digunakan untuk mengkonstruksi PDF prediktif.

Dari sekian banyak metode kalibrasi ensemble di bidang meteorologi, BMA relatif banyak digunakan, terutama setelah dikembangkan untuk model dinamis. Fenomena cuaca seringkali menunjukkan dependensi waktu dimana kejadian hari ini turut dipengaruhi oleh kejadian beberapa hari sebelumnya. BMA dapat diterapkan dengan beberapa teknik estimasi dan menunjukkan kinerja yang memuaskan, baik pada data simulasi maupun data riil (Raftery dan Zheng, 2003; Raftery *et al.*, 2005). Feldmann (2012) juga mengindikasikan BMA lebih reliabel daripada *Nonhomogeneous Gaussian Regression* (NGR) untuk prakiraan temperatur rata-rata di 14 negara bagian Jerman. Di Indonesia, salah satu penelitian yang menggunakan BMA untuk mengkalibrasi prakiraan ensemble jangka pendek dilakukan Kuswanto dan Sari (2013) untuk prakiraan temperatur.

Meskipun kinerja BMA relatif memuaskan, namun metode ini masih memiliki kelemahan. Tiap lokasi hanya dipertimbangkan secara individu (tidak serentak) dan korelasi spasial antar error diabaikan (Gel, Raftery, dan Gneiting, 2004). Akibatnya, koreksi bias metode BMA belum optimal dan *coverage* prakiraan terkadang tidak mencapai persentase yang disyaratkan. Salah satu metode yang mempertimbangkan korelasi spasial antar error adalah *Geostatistical Output Perturbation* (GOP).

GOP adalah metode prakiraan cuaca yang dihasilkan hanya dari satu luaran deterministik saja, seperti NWP. Namun, GOP dapat memodifikasi luaran tersebut, sehingga mampu membangkitkan ensemble berukuran besar berdasarkan hubungan spasial yang diidentifikasi dari error model (Gel *et al.*, 2004). GOP

memiliki tahapan estimasi parameter, seperti pemodelan geostatistika pada umumnya, yaitu penerapan MLE untuk mengestimasi parameter regresi yang dilengkapi dengan semivariogram empiris untuk mengidentifikasi korelasi spasial yang terjadi. Dari semivariogram tersebut, parameter spasial model GOP kemudian diestimasi dengan metode kuadrat terkecil terboboti (Cressie, 1985). Kemudian, prakiraan cuaca dari regresi linier sederhana ditambahkan dengan error yang disimulasikan berdasarkan estimator spasial, sehingga diperoleh prakiraan yang terkalibrasi (Berrocal, Raftery, dan Gneiting, 2007).

GOP dapat diklasifikasikan sebagai pemodelan secara multivariat karena metode ini mempertimbangkan pengaruh spasial seluruh lokasi secara serentak, meskipun hanya menggunakan satu prediktor saja pada tahap pemodelan. Walaupun GOP pada kenyataannya diaplikasikan untuk kasus kalibrasi model deterministik NWP, namun GOP mampu membangkitkan banyak anggota ensemble untuk seluruh lokasi pengamatan. Terlepas dari beberapa kelebihan yang dimiliki GOP, metode ini belum banyak diaplikasikan di Indonesia, khususnya pada penelitian meteorologi. Hal ini disebabkan GOP membutuhkan data prakiraan NWP yang cukup besar dan melingkupi wilayah yang luas agar pengaruh cuaca antar lokasi dapat tertangkap dengan baik.

Suhu udara merupakan salah satu komponen cuaca yang relatif sering diamati dan menjadi fokus penelitian. Informasi prakiraan cuaca di sebagian besar negara selalu memuat suhu udara sebagai informasi pendamping. Selain itu, suhu udara memiliki keterkaitan dengan tekanan udara, angin dan kelembapan yang secara tidak langsung dapat berpengaruh terhadap siklus pembentukan awan hujan (Wilks, 2006). Terdapat beberapa penelitian yang mengaplikasikan BMA dan GOP untuk prakiraan suhu udara terkalibrasi, diantaranya Feldmann (2012) yang mengindikasikan bahwa BMA dan GOP mampu mengkalibrasi ramalan ensemble berdasarkan CRPS yang lebih rendah.

Umumnya, prakiraan ensemble memiliki karakteristik menyerupai distribusi normal karena cenderung berpusat pada titik tertentu. Tetapi, prakiraan tersebut seringkali memiliki varians yang rendah, sehingga kemungkinan terjadinya *underdispersive* cukup tinggi. Selain itu, pola atmosfer yang dinamis dan variatif umumnya menyebabkan kondisi cuaca di suatu lokasi dipengaruhi oleh lokasi lain

yang secara geografis memiliki kedekatan. Untuk mengatasi hal tersebut, penelitian tesis ini mengaplikasikan BMA dan GOP. Kendati kedua metode dilandasi dari konsep yang berbeda, namun hasil penelitian diharapkan dapat memperlihatkan performa kedua metode dalam mengkoreksi bias prakiraan NWP.

Sebelum mengkalibrasi prakiraan ensemble dengan BMA dan GOP, reduksi dimensi parameter NWP diterapkan dengan *Principal Component Analysis* (PCA). Hal ini dilakukan untuk meminimalkan hubungan kolinier grid-grid suatu parameter akibat adanya homogenitas karakteristik. Selanjutnya, observasi riil diregresikan terhadap skor PC menggunakan regresi Ridge, *Principal Component Regression* (PCR), dan regresi *Partial Least Squares* (PLS). Pemilihan ini didasari oleh Sari (2013) bahwa PCR dan PLS mampu mengkoreksi bias NWP hingga 75%. Selain itu, tiga metode ini seringkali dapat mengatasi kasus multikolinieritas antar parameter NWP. Tiga metode tersebut yang kemudian digunakan sebagai anggota ensemble untuk diolah dengan BMA.

1.2 Rumusan Masalah

BMA merupakan salah satu metode yang dapat digunakan untuk mengkalibrasi prakiraan ensemble dan membentuk interval prediktif yang lebih reliabel. BMA mampu memanfaatkan informasi ensemble sebanyak mungkin, namun tidak mempertimbangkan korelasi spasial dalam mengkalibrasi prakiraan cuaca. Selain itu, terdapat beberapa parameter BMA yang tidak dapat diestimasi secara analitik dengan MLE. Dalam meteorologi, korelasi spasial seringkali terjadi karena kondisi cuaca suatu lokasi cenderung dipengaruhi oleh keadaan cuaca lokasi lainnya yang berdekatan. Dalam mengolah prakiraan cuaca, GOP mempertimbangkan korelasi spasial seluruh lokasi secara serentak. Meskipun hanya didasari oleh satu model prakiraan deterministik saja, GOP memiliki parameter spasial yang berfungsi untuk memperbaiki hasil prakiraan cuaca yang awalnya belum mampu mengidentifikasi fenomena spasial. Suhu udara merupakan elemen cuaca yang menjadi fokus penelitian karena memiliki kaitan yang cukup erat terhadap kejadian hujan, tekanan udara, angin, dan kelembapan. Berdasarkan uraian di atas, maka rumusan masalah dalam penelitian ini adalah

1. Bagaimana bentuk penaksiran parameter pada model BMA?

2. Bagaimana bentuk penaksiran parameter pada model GOP?
3. Bagaimana hasil prakiraan terkalibrasi untuk suhu udara harian menggunakan BMA dan GOP?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah di atas, maka tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut.

1. Mengkaji bentuk penaksir parameter model BMA.
2. Mengkaji bentuk penaksir parameter model GOP.
3. Mengaplikasikan BMA dan GOP untuk menghasilkan prakiraan suhu udara harian yang terkalibrasi.

1.4 Manfaat Penelitian

Manfaat yang ingin dicapai pada penelitian ini adalah sebagai berikut.

1. Sebagai pengembangan keilmuan metode BMA dan GOP, khususnya mengenai metode statistika yang berhubungan dengan cuaca melalui pemanfaatan data luaran NWP dan prakiraan ensemble.
2. Sebagai alternatif peramalan cuaca bagi BMKG sebagai otoritas pemerintah yang berwenang menyebarkan informasi prakiraan cuaca maupun bagi institusi lain yang berhubungan dengan meteorologi. Metode ini memberikan gambaran seberapa baik koreksi bias yang dihasilkan untuk prakiraan cuaca jangka pendek, khususnya untuk suhu udara.

1.5 Batasan Masalah

Batasan permasalahan pada penelitian ini adalah sebagai berikut.

1. Ruang lingkup penelitian dibatasi pada stasiun meteorologi terpilih dengan anggota ensemble sebanyak 3 yang diperoleh melalui PLS, PCR, dan regresi Ridge.
2. Variabel yang menjadi fokus penelitian adalah suhu udara, yaitu suhu maksimum dan suhu minimum.
3. Periode training yang digunakan adalah 30 hari karena memiliki akurasi yang cenderung lebih tinggi daripada periode yang lebih pendek maupun panjang.

BAB II

TINJAUAN PUSTAKA

2.1 Distribusi Normal

Distribusi normal merupakan distribusi probabilitas kontinu yang terpenting dalam statistika karena dapat menggambarkan beberapa kejadian di alam, industri, ekonomi, dan lingkup lainnya dengan cukup baik. Beberapa komponen cuaca, seperti pengukuran suhu udara dan tekanan udara, umumnya mengikuti sebaran berdistribusi normal (Möller, 2014). Hal ini disebabkan error model kedua komponen cuaca tersebut jarang menunjukkan gejala penyimpangan yang sangat jauh dari deviasi standar atau dengan kata lain teridentifikasi sebagai pencilan (*outlier*).

2.1.1 Distribusi Normal Univariat

Menurut Casella dan Berger (2002), distribusi normal untuk variabel random kontinu y memiliki dua parameter, yaitu mean μ dan simpangan baku σ . Mean μ merupakan parameter lokasi (parameter yang menggeser densitas distribusi ke kiri atau ke kanan), sementara σ merupakan parameter skala (parameter yang memperlebar atau mempersempit densitas distribusi, namun tidak merubah bentuk distribusi). Fungsi probabilitas distribusi normal dapat dinotasikan seperti pada persamaan (2.1).

$$g(y | \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(y-\mu)^2}, -\infty < y < \infty, -\infty < \mu < \infty, \sigma > 0 \quad (2.1)$$

2.1.2 Distribusi Normal Multivariat

Distribusi normal multivariat merupakan perluasan dari distribusi normal univariat, yang berdimensi lebih dari atau sama dengan 2. Dalam perspektif ini, normal multivariat dapat terjadi dalam kasus multi-respon yang saling berkorelasi, atau kasus yang mempertimbangkan korelasi antar ruang/lokasi (spasial). Mengacu pada persamaan (2.1), densitas normal univariat dapat diekstensi menjadi normal multivariat. Pada kasus ini, penelitian yang melibatkan banyak lokasi namun berhingga, berlaku $s \in S$ dimana s merupakan himpunan lokasi pengamatan yang *fixed* dengan koordinat lintang-bujur tertentu. Dengan

menggunakan *normalizing constant* multivariat $(2\pi)^{-s/2} |\Sigma|^{-1/2}$, densitas normal berdimensi s untuk vektor random $\mathbf{y}' = [y_1, y_2, \dots, y_s]$ adalah

$$g(\mathbf{y}) = \frac{1}{(2\pi)^{s/2} |\Sigma|^{1/2}} e^{-\frac{(\mathbf{y}-\boldsymbol{\mu})' \Sigma^{-1} (\mathbf{y}-\boldsymbol{\mu})}{2}}, -\infty < y_i < \infty, i = 1, 2, \dots, s. \quad (2.2)$$

Densitas normal berdimensi s pada persamaan (2.2) dapat dinyatakan oleh $N_s(\boldsymbol{\mu}, \Sigma)$ dengan $\boldsymbol{\mu} = [\mu_1 \ \mu_2 \ \dots \ \mu_s]'$ merupakan vektor mean populasi berukuran $s \times 1$ dan Σ merupakan matrik varians-kovarian berukuran $s \times s$.

2.2 Principal Component Analysis (PCA)

Menurut Johnson dan Wichern (2007), *Principal Component Analysis* (PCA) adalah suatu metode tingkat menengah, digunakan untuk menjelaskan struktur varians-kovarian banyak variabel berdasarkan beberapa kombinasi linier yang terbentuk. PCA umumnya digunakan untuk mereduksi data dengan banyak variabel yang saling berkorelasi agar memudahkan interpretasi (Jolliffe, 2002). Hal tersebut dilakukan dengan mentransformasikan variabel-variabel asal ke beberapa komponen utama PC, yang diharapkan tidak lagi saling berkorelasi.

Mengacu pada perspektif aljabar linier, PC dipandang sebagai kombinasi linier dari p variabel random x_1, x_2, \dots, x_p . Kombinasi linier tersebut secara geometrik merepresentasikan pembentukan sistem koordinat yang baru dengan merotasi sistem koordinat asal dimana x_1, x_2, \dots, x_p berlaku sebagai sumbu koordinat. Struktur kovarian akan menjadi lebih sederhana dan interpretasi menjadi lebih mudah dengan adanya sumbu terbaru yang memiliki varians (keragaman) maksimal (Johnson dan Wichern, 2007). Syarat pembentukan PC sebagai kombinasi linier dari vektor random $\mathbf{x}' = [x_1, x_2, \dots, x_p]$ agar mampu mewakili keragaman yang tinggi adalah dengan memilih vektor eigen $\mathbf{e}_i' = [e_{i1}, e_{i2}, \dots, e_{ip}]$ sedemikian hingga $\text{var}(\mathbf{e}_i' \mathbf{x})$ bernilai maksimum dimana $\mathbf{e}_i' \mathbf{e}_i = 1$ dan $\text{cov}(\mathbf{e}_i' \mathbf{x}, \mathbf{e}_m' \mathbf{x}) = 0$ untuk $i \neq m$, dimana $i, m = 1, 2, \dots, p$.

Berdasarkan Johnson dan Wichern (2002), PC dapat dibentuk dari matrik kovarian dan matrik korelasi dimana matrik korelasi digunakan jika variabel

penelitian memiliki satuan pengukuran yang beragam, sebaliknya matrik kovarian digunakan untuk variabel dengan satuan pengukuran yang relatif sama. Meski demikian, tidak banyak ditemukan variabel penelitian dengan satuan yang sama. Jolliffe (2002) menyatakan bahwa standardisasi variabel dapat menjadi alternatif untuk mengatasi problem satuan yang berbeda. Standardisasi data menyebabkan matrik varians-kovarian data yang distandardisasi akan sama dengan/menyerupai matrik korelasi data sebelum standardisasi dan total varians PC akan sama besar dengan banyaknya variabel asal.

Secara umum, vektor random \mathbf{x}' memiliki matrik varians-kovarian Σ dengan akar ciri (*eigen value*) berturut-turut yaitu $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$, sehingga kombinasi linier utama adalah seperti pada persamaan (2.3) (Johnson dan Wichern, 2007).

$$\begin{aligned} PC_1 &= \mathbf{e}_1' \mathbf{x} = e_{11}x_1 + e_{12}x_2 + \dots + e_{1p}x_p \\ PC_2 &= \mathbf{e}_2' \mathbf{x} = e_{21}x_1 + e_{22}x_2 + \dots + e_{2p}x_p \\ &\vdots \\ PC_p &= \mathbf{e}_p' \mathbf{x} = e_{p1}x_1 + e_{p2}x_2 + \dots + e_{pp}x_p \end{aligned} \quad (2.3)$$

dengan:

PC_1 = PC pertama, yang mempunyai varians terbesar

PC_2 = PC kedua, yang mempunyai varians terbesar kedua

PC_p = PC ke- p , yang mempunyai varians terbesar ke- p

x_1 = variabel random pertama

x_2 = variabel random kedua

x_p = variabel random ke- p

\mathbf{e}_p = vektor karakteristik (*eigen vector*) PC ke- p

Jadi, PC ke- i diberikan oleh persamaan berikut:

$$PC_i = \mathbf{e}_i' \mathbf{x}, \text{ dimana : } i = 1, 2, \dots, p,$$

dengan keterangan yang terkait dengan PC_i seperti ditunjukkan pada persamaan (2.4) dan (2.5).

$$\text{Var}(PC_i) = \mathbf{e}_i' \Sigma \mathbf{e}_i = \lambda_i, \quad i = 1, 2, \dots, p \quad (2.4)$$

$$\text{Cov}(PC_i, PC_m) = \mathbf{e}_i' \Sigma \mathbf{e}_m = 0, \quad i \neq m \quad (2.5)$$

PC yang terbentuk diharapkan tidak saling berkorelasi dan memiliki varians yang sama dengan akar ciri (*eigen value*) dari Σ , sehingga total varians (keragaman) terjelaskan dinotasikan pada persamaan (2.6),

$$\sum_{i=1}^p \text{Var}(x_i) = \sigma_{11} + \sigma_{22} + \dots + \sigma_{pp} \quad (2.6)$$

$$\sum_{i=1}^p \text{Var}(\text{PC}_i) = \lambda_1 + \lambda_2 + \dots + \lambda_p$$

Persentase varians (keragaman) total yang dapat diterangkan oleh PC ke- i ditunjukkan pada persamaan (2.7), dimana

$$\text{proporsi varians PC ke-}i = \frac{\lambda_i}{\lambda_1 + \lambda_2 + \dots + \lambda_p} \quad (2.7)$$

Apabila PC yang diambil sebanyak m dimana ($m < p$), maka persamaan (2.8) menjelaskan bahwa

$$\text{proporsi varians } m \text{ PC} = \frac{\lambda_1 + \lambda_2 + \dots + \lambda_m}{\lambda_1 + \lambda_2 + \dots + \lambda_p} \quad (2.8)$$

Menurut Johnson dan Wichern (2007) dan Jolliffe (2002), terdapat beberapa acuan yang dapat digunakan untuk menentukan banyaknya PC, antara lain:

1. Melihat pola *scree plot* yang menggambarkan besarnya *eigenvalue* $\hat{\lambda}_i$.
Banyaknya PC yang terpilih ditentukan oleh range terbesar antar titik dimana proses pemilihan PC akan dihentikan jika range antar titik makin rendah (terlihat kelandaian). Namun, pendekatan ini lebih bersifat subjektif, sehingga diperlukan pendekatan lain yang lebih objektif.
2. Pemilihan PC berdasarkan banyaknya *eigen value* yang lebih besar dari satu, yang merepresentasikan tingginya tingkat homogenitas antar variabel.
3. PC-PC yang terpilih diharapkan dapat memberikan kumulatif persentase varians 80% - 90%.

2.3 Partial Least Squares (PLS)

Jika q variabel respon Y_1, \dots, Y_q diprediksi dengan p variabel prediktor X_1, \dots, X_p , dengan data terdiri atas n observasi, maka elemen pasangan respon dan prediktor dapat ditulis sebagai berikut, yaitu $(\mathbf{x}'_t, \mathbf{y}'_t)$, dimana $t = 1, \dots, n$. Metode PLS diawali dengan standardisasi data, baik variabel X maupun variabel Y . Salah satu teknik standardisasi adalah dengan mengurangi nilai tiap pengamatan dengan

rata-rata dan dibagi akar varians. Tujuan standardisasi data adalah untuk memperoleh pembobot dengan satuan yang relatif sama antar variabel berdasarkan metode perhitungan pada persamaan (2.9),

$$\begin{aligned} x_{tu}^* &= \frac{x_{tu} - \bar{x}_u}{s_u} \\ y_{tr}^* &= \frac{y_{tr} - \bar{y}_r}{s_r} \end{aligned} \quad (2.9)$$

dengan

$$\begin{aligned} \bar{x}_u &= \frac{1}{n} \sum_{t=1}^n x_{tu} ; s_u = \sqrt{\frac{\sum_{t=1}^n (x_{tu} - \bar{x}_u)^2}{n-1}} , \\ \bar{y}_r &= \frac{1}{n} \sum_{t=1}^n y_{tr} ; s_r = \sqrt{\frac{\sum_{t=1}^n (y_{tr} - \bar{y}_r)^2}{n-1}} . \end{aligned}$$

Pada persamaan (2.9), x_{tu}^* adalah data ke- t yang telah distandardisasi untuk variabel prediktor ke- u dimana $u = 1, 2, \dots, p$, sedangkan y_{tr}^* adalah data ke- t yang telah distandardisasi untuk variabel respon ke- r dimana $r = 1, 2, \dots, q$.

Kemudian, $\mathbf{x}_t' = (x_{t1}, \dots, x_{tp})$ dihimpun dalam matrik \mathbf{X} yang berukuran $n \times p$ begitu juga dengan matrik \mathbf{Y} yang berukuran $n \times q$ berisikan $\mathbf{y}_t' = (y_{t1}, \dots, y_{tq})$.

Persamaan (2.10) menunjukkan himpunan matrik \mathbf{X} dan \mathbf{Y} tersebut

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}_1' \\ \vdots \\ \mathbf{x}_n' \end{bmatrix} \text{ dan } \mathbf{Y} = \begin{bmatrix} \mathbf{y}_1' \\ \vdots \\ \mathbf{y}_n' \end{bmatrix} \quad (2.10)$$

dimana n adalah banyak observasi, p adalah banyaknya prediktor dan q adalah banyaknya respon. Ketika $n < p$, metode regresi yang umum digunakan dengan teknik estimasi *Ordinary Least Squares* (OLS) tidak dapat diaplikasikan karena matrik kovarian $(\mathbf{X}'\mathbf{X})$ adalah singular. Sebaliknya, PLS dapat diaplikasikan untuk kasus-kasus $n < p$ dan mampu menangani kasus ini dengan cukup baik.

Dalam PLS, reduksi dimensi dan regresinya (pemodelan) dilakukan secara simultan. \mathbf{T} yang dinotasikan sebagai variabel laten atau *scores* merupakan hasil dekomposisi matrik dari variabel acak observasi. \mathbf{P} dinyatakan sebagai *X-loadings*

dan \mathbf{Q} dinyatakan sebagai *Y-loadings*. Regresi PLS didasarkan pada dekomposisi komponen laten seperti persamaan (2.11),

$$\begin{aligned}\mathbf{X} &= \mathbf{TP}' + \mathbf{E} \\ \mathbf{Y} &= \mathbf{TQ}' + \mathbf{F}\end{aligned}\tag{2.11}$$

dengan:

\mathbf{T} = matrik komponen laten (*scores matrices*) untuk n pengamatan yang berukuran $n \times c$

\mathbf{P} = matrik koefisien (*loadings matrices*) variabel \mathbf{X} yang berukuran $p \times c$

\mathbf{Q} = matrik koefisien (*loadings matrices*) variabel \mathbf{Y} yang berukuran $q \times c$

\mathbf{E} dan \mathbf{F} = matrik residual (Wold, Sjöström, dan Eriksson, 2001).

Masih menurut Wold, Sjöström, dan Eriksson (2001), PLS memiliki kesamaan dengan regresi PCR dimana PLS membentuk matrik komponen laten \mathbf{T} sebagai transformasi linier dari \mathbf{X} dan hubungan tersebut disajikan pada persamaan (2.12).

$$\mathbf{T} = \mathbf{XW}\tag{2.12}$$

\mathbf{W} adalah matrik *weight* (pembobot) yang berukuran $p \times c$ dengan c adalah banyaknya komponen laten, selanjutnya \mathbf{W} dan \mathbf{T} dinotasikan sebagai berikut :

$$\mathbf{w}_j = \begin{bmatrix} w_{1j} \\ \vdots \\ w_{pj} \end{bmatrix} \text{ dan } \mathbf{t}_j = \begin{bmatrix} t_{1j} \\ \vdots \\ t_{nj} \end{bmatrix}, \text{ untuk } j = 1, 2, \dots, c.$$

Komponen laten berperan sebagai variabel asal \mathbf{X} dan digunakan untuk memprediksi \mathbf{Y} . Ketika \mathbf{T} sudah terbentuk, maka diperoleh \mathbf{Q}' melalui metode kuadrat terkecil dengan formulasi yang ditunjukkan pada persamaan (2.13).

$$\mathbf{Q}' = (\mathbf{T}'\mathbf{T})^{-1}\mathbf{T}'\mathbf{Y}\tag{2.13}$$

Dengan demikian, berdasarkan Wold, Sjöström, dan Eriksson (2001), matrik koefisien regresi untuk model $\mathbf{Y}=\mathbf{XB}+\mathbf{F}$ (analog dengan model OLS) adalah matrik \mathbf{B} dimana estimator \mathbf{B} diperoleh dari penurunan singkat berikut.

$$\mathbf{Y} = \mathbf{XB} + \mathbf{F} = \mathbf{TQ}' + \mathbf{F} \text{ (diperoleh dari persamaan (2.11))}$$

$$\iff \mathbf{XB} = \mathbf{TQ}'$$

$$\iff \mathbf{XB} = \mathbf{XWQ}'$$

$$\iff \mathbf{B} = \mathbf{WQ}' \text{ (} \mathbf{Q}' \text{ disubstitusi dari persamaan (2.13))}$$

Jadi, estimator untuk \mathbf{B} adalah seperti yang ditunjukkan persamaan (2.14),

$$\hat{\mathbf{B}} = \mathbf{W}(\mathbf{T}'\mathbf{T})^{-1}\mathbf{T}'\mathbf{Y} \quad (2.14)$$

dimana dapat disimpulkan bahwa dugaan \mathbf{Y} diperoleh berdasarkan persamaan (2.15).

$$\begin{aligned} \hat{\mathbf{Y}} &= \mathbf{X}\hat{\mathbf{B}} \\ \hat{\mathbf{Y}} &= \left[\mathbf{T}\mathbf{W}^{-1}\mathbf{W}(\mathbf{T}'\mathbf{T})^{-1}\mathbf{T}'\mathbf{Y} \right] \\ \hat{\mathbf{Y}} &= \left[\mathbf{T}\mathbf{I}(\mathbf{T}'\mathbf{T})^{-1}\mathbf{T}'\mathbf{Y} \right] = \left[\mathbf{T}(\mathbf{T}'\mathbf{T})^{-1}\mathbf{T}'\mathbf{Y} \right] \end{aligned} \quad (2.15)$$

Karakteristik berbagai pendekatan regresi PLS dapat dilakukan dengan menitikberatkan pada empat hal berikut (Wold, Sjöström, dan Eriksson, 2001).

1. Fungsi objektif yang dimaksimumkan oleh matrik pembobot \mathbf{W}
2. Nilai matrik pembobot \mathbf{W}
3. Matrik koefisien regresi \mathbf{B}
4. Algoritma yang digunakan untuk menghitung pembobot \mathbf{W}

2.4 *Principal Component Regression (PCR)*

Principal Component Regression (PCR) adalah metode yang dapat digunakan untuk mengatasi multikolinieritas tanpa harus mengeluarkan prediktor yang terlibat hubungan kolinear. Dengan demikian, seluruh prediktor berkontribusi dalam pemodelan. Konsep utama dari PCR ialah menyederhanakan banyaknya prediktor dengan cara mereduksi dimensinya. Hal ini dilakukan dengan cara mereduksi korelasi antar variabel bebas melalui transformasi prediktor asal ke variabel baru yang tidak lagi berkorelasi, dapat disebut sebagai komponen utama (PC). Setelah satu atau beberapa PC diperoleh, seluruh PC terpilih tersebut menjadi prediktor baru yang akan diregresikan atau dianalisis pengaruhnya terhadap variabel respon dengan menggunakan analisis regresi (Jolliffe, 2002).

Cara pembentukan PCR melalui PCA ada dua cara, yaitu dengan menggunakan matrik kovarian atau matrik korelasi. Kedua cara tersebut digunakan berdasarkan tinggi rendahnya skala pengamatan antar prediktor (Johnson dan Wichern, 2002). Dalam penelitian ini, regresi komponen utama dibentuk berdasarkan matrik kovarian karena data terlebih dulu distandardisasi

sebelum diolah/dimodelkan, sehingga perbedaan skala pengukuran antar variabel menjadi tidak signifikan atau relatif seimbang.

Dimisalkan bahwa $\mathbf{x}' = [x_1, x_2, \dots, x_p]$ merupakan vektor prediktor dari matrik \mathbf{X} berukuran $n \times p$. Jika matrik \mathbf{A} adalah matrik ortogonal berukuran $p \times p$ dengan kolom ke- m berisikan vektor eigen ke- m dari $\mathbf{X}'\mathbf{X}$ dengan asumsi $m \leq p$, maka $\mathbf{A}'\mathbf{A} = \mathbf{A}\mathbf{A}' = \mathbf{I}$. Skor PC untuk tiap pengamatan adalah

$$\mathbf{Z} = \mathbf{X}\mathbf{A} \quad (2.16)$$

dengan elemen (i, m) dari \mathbf{Z} merupakan skor dari PC ke- m untuk pengamatan ke- i dimana $i = 1, 2, \dots, n$.

Berdasarkan sifat ortogonal \mathbf{A} dalam Jolliffe (2002), regresi linear berganda dengan prediktor yang saling berkorelasi dapat dikonversikan ke dalam PCR, seperti pada persamaan (2.17),

$$\begin{aligned} \mathbf{y} &= \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \\ \mathbf{y} &= \mathbf{X}\mathbf{A}\mathbf{A}'\boldsymbol{\beta} + \boldsymbol{\varepsilon} \text{ karena } \mathbf{A}\mathbf{A}' = \mathbf{I} \\ \mathbf{y} &= \mathbf{Z}\boldsymbol{\gamma} + \boldsymbol{\varepsilon} \end{aligned} \quad (2.17)$$

dengan $\mathbf{X}\mathbf{A} = \mathbf{Z}$ dan $\mathbf{A}'\boldsymbol{\beta} = \boldsymbol{\gamma}$. Estimasi untuk $\boldsymbol{\gamma}$ dapat dilakukan dengan metode OLS, lalu mencari estimasi $\boldsymbol{\beta}$ berdasarkan persamaan (2.18).

$$\hat{\boldsymbol{\beta}} = \mathbf{A}\hat{\boldsymbol{\gamma}} \quad (2.18)$$

Karena data pada awalnya distandardisasi, maka diperlukan transformasi sedemikian hingga respon (Y) kembali ke satuan semula, yaitu dengan mengalikan Y terhadap akar variansnya, lalu dijumlahkan dengan rata-ratanya.

2.5 Regresi Ridge

Regresi Ridge merupakan salah satu dari sekian banyak metode yang digunakan untuk mereduksi pengaruh dari prediktor yang saling berkorelasi. Berdasarkan Rencher dan Schaalje (2008), singularitas $\mathbf{X}'\mathbf{X}$ akibat multikolinieritas dapat menyebabkan estimasi $\boldsymbol{\beta}$ menjadi tidak efisien (varians yang besar). Hal ini dikarenakan estimasi OLS ataupun estimasi MLE yang umumnya bergantung pada hasil $(\mathbf{X}'\mathbf{X})^{-1}$. Selain itu, regresi ini sesuai pada kasus dengan jumlah prediktor yang lebih banyak daripada jumlah observasi.

Estimator β , seperti pada persamaan (2.19) yang diperoleh melalui OLS, dapat menimbulkan permasalahan jika terjadi multikolinieritas sempurna atau mendekati sempurna yang berdampak pada tidak validnya hasil pengujian parameter regresi dan selang kepercayaan yang melebar. Dampak lainnya adalah berbedanya tanda koefisien regresi dari yang diharapkan.

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} \quad (2.19)$$

Berdasarkan Draper dan Smith (1992), regresi Ridge menggunakan suatu konstanta non-negatif λ yang memodifikasi persamaan (2.19) untuk menghitung koefisien regresi yang lebih efisien, meskipun bias. Persamaan (2.20) merupakan persamaan yang lazimnya digunakan untuk mengestimasi koefisien regresi Ridge.

$$\hat{\beta}_{ridge} = (\mathbf{X}'\mathbf{X} + \lambda \mathbf{I})^{-1} \mathbf{X}'\mathbf{y} \quad (2.20)$$

Serupa dengan PLS dan PCR, pada regresi Ridge, disarankan untuk melakukan standardisasi terhadap prediktor dan respon sehingga perbedaan skala perhitungan antar prediktor tidak terlampaui signifikan. Konstanta λ dapat dipilih secara intuitif (*by default*) atau dengan teknik *cross-validation* berdasarkan RMSE terendah. Makin tinggi λ , maka koefisien β_p makin mendekati 0 atau menyebabkan parameter p kurang berpengaruh terhadap respon.

2.6 Bayesian Model Averaging (BMA)

Menurut Jolliffe dan Stephenson (2011), hasil prakiraan ensemble cenderung bersifat *underdispersive* atau *overdispersive* (nilai prakiraan cuaca terpusat pada suatu nilai dengan varians yang rendah atau tinggi). Keadaan yang demikian dapat menyebabkan hasil prakiraan menjadi kurang reliabel sebab *underdispersive* mengindikasikan interval prakiraan yang relatif sempit, sementara *overdispersive* mengindikasikan interval prakiraan yang relatif lebih lebar. Permasalahan tersebut dapat ditangani dengan kalibrasi prakiraan ensemble untuk menghasilkan fungsi padat probabilitas (PDF) prediktif yang lebih reliabel dan tajam. Jika interval prakiraan ensemble terkalibrasi memiliki standar deviasi dengan ukuran yang proporsional, maka hasil prakiraan tersebut mencapai keadaan *equidispersive*.

Salah satu metode yang dapat digunakan untuk mengkalibrasi prakiraan ensemble adalah *Bayesian Model Averaging* atau BMA, yang awalnya digunakan pada bidang sosial dan kesehatan. Aplikasi BMA untuk meteorologi diinisiasi oleh Raftery *et al.* (2005) yang mengembangkan metode ini berdasarkan konsep model dinamis. Kelebihan metode ini terletak pada kemampuan dalam memadukan beberapa model prakiraan ensemble dan mengkoreksi bias prakiraan agar mean dan varians makin mendekati kenyataan, sehingga prakiraan ensemble yang terkalibrasi dapat mendekati nilai observasi yang sesungguhnya. Dengan memanfaatkan informasi dari beberapa model ensemble, maka prakiraan yang dihasilkan tidak hanya bergantung pada salah satu model saja. Selain itu, estimator parameter BMA tidak stagnan dan selalu berubah mengikuti informasi cuaca dan atmosfer yang dinamis.

Fungsi padat probabilitas (PDF) prediktif BMA merupakan kombinasi linier beberapa model prakiraan dimana tiap model memiliki kontribusi atau bobot (*weight*) yang berbeda terhadap pembentukan PDF prediktif. Dalam BMA, penentuan bobot dilakukan berdasarkan konsep rata-rata (*model averaging*). Besaran bobot tergantung dari kemampuan model dalam melakukan prakiraan komponen cuaca dimana bobot akan semakin besar jika hasil prakiraan semakin mendekati nilai observasi riil. Dari sudut pandang Bayesian, bobot-bobot tersebut merupakan probabilitas posterior masing-masing anggota/model ensemble (Feldmann, 2012).

Dimisalkan bahwa pada suatu lokasi tertentu, y adalah nilai riil dari elemen cuaca yang menjadi fokus penelitian dengan f_1, f_2, \dots, f_M adalah kumpulan M -model prakiraan yang berbeda. Koreksi bias dari tiap anggota ensemble m dapat direpresentasikan ke persamaan (2.21).

$$y = \beta_{0,m} + \beta_{1,m}f_m + \varepsilon_m \quad (2.21)$$

Dalam kerangka kerja BMA, tiap prakiraan anggota ensemble f_m , $m = 1, 2, \dots, M$, memiliki PDF posterior $g_m(y | f_m)$ yang dapat diinterpretasikan sebagai densitas dari y jika f_m merupakan prakiraan anggota ensemble “terbaik” (Raftery *et al.*, 2005).

Mengacu pada teorema probabilitas total, PDF posterior (prediktif) dari y berdasarkan data training $D = [y_1^{obs}, y_2^{obs}, \dots, y_T^{obs}]$ adalah

$$g(y | f_1, \dots, f_M, D) = \sum_{m=1}^M g(y | f_m, D) g(f_m | D) \quad (2.22)$$

dimana persamaan (2.22) adalah PDF posterior hasil rata-rata dari PDF posterior tiap anggota ensemble, diboboti oleh probabilitas posterior dari tiap anggota ensemble (Raftery dan Zheng, 2003). Probabilitas posterior untuk anggota ensemble f_m adalah seperti yang ditunjukkan pada persamaan (2.23)

$$g(f_m | D) = \frac{g(D | f_m) g(f_m)}{\sum_{l=1}^M g(D | f_l) g(f_l)} \quad (2.23)$$

dimana $g(D | f_m) = \int g(D | \theta_m, f_m) g(\theta_m | f_m) d\theta_m$ merupakan likelihood anggota ensemble m yang diintegralkan, θ_m adalah vektor parameter anggota ensemble m (misal $\theta = [\beta_0, \beta_1, \sigma^2]$), $g(\theta_m | f_m)$ adalah densitas prior θ_m untuk prakiraan ensemble f_m , $g(D | \theta_m, f_m)$ adalah likelihood, dan $g(f_m)$ adalah probabilitas prior untuk tiap ensemble m yang umumnya sebesar $1/M$.

Berdasarkan Raftery *et al.* (2005), persamaan (2.22) dapat dimodifikasi untuk kasus model dinamis, sehingga model prediktif BMA menjadi

$$g(y | f_1, f_2, \dots, f_M) = \sum_{m=1}^M w_m g_m(y | f_m) \quad (2.24)$$

dengan w_m merupakan probabilitas posterior dari anggota ensemble m yang dianggap sebagai model “terbaik” dimana w_1, \dots, w_M adalah non-negatif dan $w_1 + w_2 + \dots + w_M = 1$. Persamaan (2.24) mengindikasikan bahwa PDF prediktif adalah model *mixture* dari beberapa densitas posterior. Bobot w_m pada persamaan (2.24) ditentukan oleh kemampuan peramalan tiap anggota ensemble selama periode *training*. PDF prediktif BMA untuk model dinamis pada persamaan (2.24) dirancang untuk kasus univariat, baik dari aspek banyak variabel respon, lokasi, dan *lead* waktu peramalan, misal dikhususkan untuk prakiraan 24 jam ke depan saja, sehingga korelasi spasial atau temporal antar error tidak dapat ditangani (Feldmann, 2012; Möller, 2014).

Pada BMA, koreksi bias dilakukan dengan menerapkan transformasi linier $\beta_{0,m} + \beta_{1,m}f_m$ untuk tiap anggota ensemble (Raftery *et al.*, 2005). Transformasi tersebut berkaitan dengan ekspektasi dari densitas bersyarat p_m . Parameter $\beta_{0,m}$ dan $\beta_{1,m}$ masing-masing adalah term koreksi bias adaptif dan multiplikatif yang diperoleh dari regresi linier sederhana antara observasi y dan f_m selama periode *training*. Jika prakiraan anggota ensemble f_m berdistribusi normal univariat, maka distribusi posterior dari y jika f_m merupakan anggota ensemble yang “terbaik” adalah

$$y | f_m \sim N(\beta_{0,m} + \beta_{1,m}f_m, \sigma^2) \quad (2.25)$$

dengan varians σ^2 yang diasumsikan konstan untuk seluruh anggota ensemble m .

Penentuan distribusi yang digunakan untuk menghitung densitas posterior y umumnya dilakukan dengan mengidentifikasi karakteristik data komponen cuaca. Suhu dan tekanan udara umumnya mengikuti distribusi normal seperti dinyatakan pada persamaan (2.25), sementara curah hujan dan kecepatan angin cenderung mengikuti distribusi Gamma (Möller, 2014). Berdasarkan Raftery *et al.* (2005), mean posterior (prediktif) BMA dinyatakan dalam persamaan (2.26), prakiraan deterministik, yaitu rata-rata terboboti dari prakiraan ensemble yang sudah terkalibrasi,

$$E(y | f_1, \dots, f_M) = \sum_{m=1}^M w_m (\hat{\beta}_{0,m} + \hat{\beta}_{1,m}f_m), \quad (2.26)$$

dan varians posterior (prediktif) BMA adalah

$$\text{var}(y | f_1, \dots, f_M) = \sum_{m=1}^M w_m \left((\hat{\beta}_{0,m} + \hat{\beta}_{1,m}f_m) - \sum_{m=1}^M w_m (\hat{\beta}_{0,m} + \hat{\beta}_{1,m}f_m) \right)^2 + \sigma^2. \quad (2.27)$$

Secara verbal, persamaan (2.27) dapat pula direpresentasikan ke dalam persamaan (2.28).

$$\text{Varians prediktif} = \text{Varians antar ensemble} + \text{Varians dalam ensemble} \quad (2.28)$$

Jika ditetapkan observasi riil y_t dan prakiraan ensemble sebanyak M f_{1t}, \dots, f_{Mt} untuk suatu waktu (jam, hari atau bulan) t selama periode *training* tertentu pada suatu lokasi, seluruh parameter BMA dapat diestimasi melalui 3 tahapan berikut:

- 1) Parameter $\beta_{0,m}$ dan $\beta_{1,m}$ untuk $m=1,2,\dots,M$ diestimasi dengan regresi linier sederhana antara observasi y_t dan f_{mt} .
- 2) Bobot w_m untuk $m=1,2,\dots,M$ dan varians diestimasi dengan memaksimumkan fungsi log-likelihood pada persamaan (2.29), dengan asumsi error prakiraan tidak saling berkorelasi antar lokasi dan waktu.

$$l(w_1, \dots, w_M, \sigma^2) = \sum_t \log \left(\sum_{m=1}^M w_m g_m(y_t | f_{mt}) \right) \quad (2.29)$$

- 3) Diperoleh bahwa persamaan (2.29) tidak dapat diselesaikan secara analitik. Terdapat beberapa pendekatan numerik yang digunakan untuk mengatasi permasalahan tersebut, salah satunya dengan algoritma *Expectation-Maximization* (EM) seperti pada Raftery *et al.* (2005) yang digagas oleh Dempster, Laird, dan Rubin (1977). Dimisalkan terdapat himpunan variabel laten yang tidak teramati $z_t = [z_{1t}, \dots, z_{Mt}]$, maka variabel laten yang tidak teramati z_{mt} akan bernilai 1 jika anggota ensemble m adalah prakiraan terbaik pada waktu t dan bernilai 0 jika bukan prakiraan terbaik. Himpunan z_t hanya memiliki satu elemen z_{mt} saja yang bernilai 1, sementara sisanya bernilai 0. Algoritma EM diawali oleh tahap *expectation* dimana nilai z_{mt} diestimasi secara berulang berdasarkan bobot dan varians yang sudah ditentukan pada tahap inisiasi, dinyatakan dalam persamaan (2.30)

$$\hat{z}_{mt}^{(i)} = \frac{w_m g_m(y_t | f_{mt}, \sigma^{(i-1)})}{\sum_{l=1}^M w_l g_l(y_t | f_{lt}, \sigma^{(i-1)})} \quad (2.30)$$

dengan i adalah iterasi dan $g_m(y_t | f_{mt}, \sigma^{(i-1)})$ adalah PDF bersyarat dari anggota ensemble m yang dihitung pada observasi y_t dengan mean $\mu_{mt} = \hat{\beta}_{0,m} + \hat{\beta}_{1,m} f_{mt}$ dan standar deviasi $\sigma^{(i-1)}$ yang dievaluasi dari observasi cuaca y . Pada tahap berikutnya, tahap *maximization*, bobot dan varians diperbarui berdasarkan $\hat{z}_{mt}^{(i)}$ yang dinyatakan dalam persamaan (2.31).

$$\begin{aligned}
w_m^{(i)} &= \frac{1}{T} \sum_{t=1}^T \hat{z}_{mt}^{(i)} \\
\sigma^{2(i)} &= \frac{1}{T} \sum_{t=1}^T \sum_{m=1}^M \hat{z}_{mt}^{(i)} (y_t - f_{mt})^2
\end{aligned} \tag{2.31}$$

Konvergensi bobot dan varians tercapai jika selisih antar bobot, antar varians, dan antar \hat{z}_{mt} di tiap iterasi lebih kecil dari batas toleransi yang ditentukan.

2.7 Geostatistical Output Perturbation (GOP)

Teknologi dan metode yang digunakan untuk prakiraan cuaca saat ini sudah berkembang pesat, antara lain dengan memadukan beberapa metode, sehingga diperoleh data ensemble yang kemudian digunakan sebagai acuan untuk prakiraan cuaca. Namun, teknik ini tidak dapat diaplikasikan dengan optimal tanpa dukungan data atmosfer yang besar dan teknologi komputasi yang canggih. Permasalahan ini seringkali ditemui di banyak negara berkembang yang minim sumber daya. Untuk mengatasi hal tersebut, Gel *et al.* (2004) memodifikasi keluaran NWP yang bersifat deterministik dengan memasukkan pengaruh error yang berdistribusi normal. Error tersebut dapat dimodifikasi dan dibangkitkan melalui simulasi model geostatistika hingga diperoleh prakiraan terkalibrasi yang reliabel dan tetap tajam. Selain itu, GOP juga mampu menangkap pola dependensi spasial yang seringkali teridentifikasi pada error model.

Berdasarkan Gel *et al.* (2004), dimisalkan S adalah himpunan lokasi pengamatan yang cukup besar, namun berhingga (*finite*) dimana waktu $t \in T$ dan periode *training* dianggap *fixed*. Prediktor yang digunakan umumnya hanya ada 1, misal keluaran NWP pada domain grid yang bersesuaian/berdekatan dengan lokasi pengamatan. Pada periode *training* $t=1,2,\dots,T$ untuk seluruh lokasi s dimana $s \in S$, berlaku persamaan (2.32)

$$y_{s,t} = \beta_0 + \beta_1 x_{s,t} + \varepsilon_{s,t} \tag{2.32}$$

dimana $y_{s,t}$ adalah respon (observasi suhu udara) pada stasiun s hari ke- t , $x_{s,t}$ adalah prediktor (NWP suhu udara) pada grid terdekat dari stasiun s , dan $\varepsilon_{s,t}$ adalah error regresi. Untuk stasiun s yang sama, error $\varepsilon_{s,t}$ untuk suhu udara

disyaratkan memenuhi asumsi error identik, independen, dan berdistribusi normal. Melalui estimasi dengan OLS atau MLE, diperoleh persamaan (2.33) bahwa

$$\hat{\beta}_1 = \frac{n \sum_{j=1}^n x_j y_j - \left(\sum_{j=1}^n x_j \right) \left(\sum_{j=1}^n y_j \right)}{n \sum_{j=1}^n x_j^2 - \left(\sum_{j=1}^n x_j \right)^2} = \frac{\sum_{j=1}^n (x_j - \bar{x})(y_j - \bar{y})}{\sum_{j=1}^n (x_j - \bar{x})^2}; \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \quad (2.33)$$

dimana n adalah banyaknya pasangan $\{s, t\}$. Dapat dikatakan bahwa besar kemungkinan error antar lokasi tidak independen karena adanya pengaruh spasial.

Dengan mempertimbangkan aspek multivariat antar lokasi, untuk $t = 1, 2, \dots, T$, berlaku $\mathbf{y}_t = [y_{1t}, y_{2t}, \dots, y_{st}]'$ vektor elemen cuaca yang diamati di seluruh lokasi pengamatan berukuran $s \times 1$ dan $\mathbf{x}_t = [x_{1t}, x_{2t}, \dots, x_{st}]'$ vektor prakiraan cuaca berukuran $s \times 1$

$$\mathbf{y}_t = \beta_0 \mathbf{1} + \beta_1 \mathbf{x}_t + \boldsymbol{\varepsilon}_t \quad (2.34)$$

dengan $\mathbf{1}$ adalah vektor berukuran $s \times 1$ yang seluruh elemennya bernilai 1 dan $\boldsymbol{\varepsilon}_t = [\varepsilon_{1t}, \varepsilon_{2t}, \dots, \varepsilon_{st}]'$. Error model GOP dari persamaan (2.34) berdistribusi normal dengan mean $\mathbf{0}$ dan kovarian $\boldsymbol{\Sigma}$ yang nilainya bergantung pada struktur kovarians dari error secara spasial.

Jika $C(\mathbf{s}_i, \mathbf{s}_j)$ pada persamaan (2.35) merupakan fungsi korelasi yang stasioner dan isotropi, maka nilai elemen (i, j) $\boldsymbol{\Sigma}$ diperoleh melalui

$$\frac{1}{2} \text{var}(\varepsilon(\mathbf{s}_i) - \varepsilon(\mathbf{s}_j)) = \rho^2 + \sigma^2 (1 - C(\mathbf{s}_i, \mathbf{s}_j)) \quad (2.35)$$

Dalam terminologi geostatistika, ρ^2 adalah efek *nugget* yang dapat bermakna ganda, yaitu varians kesalahan pengukuran/instrumen/alat dan juga ukuran dari keragaman spasial pada jarak tertentu yang masih memberikan pengaruh, $\rho^2 + \sigma^2$ adalah varians marginal dari residual atau *sill* (Cressie, 1993).

Terdapat beberapa fungsi korelasi yang dapat digunakan untuk memodelkan struktur spasial, antara lain fungsi korelasi eksponensial Gel *et al.* (2004), yaitu

$$C(\mathbf{s}_i, \mathbf{s}_j) = \exp\left(-\frac{\|\mathbf{s}_i - \mathbf{s}_j\|}{r}\right) \quad (2.36)$$

dimana $\|\cdot\|$ dan r pada persamaan (2.36) masing-masing adalah norm Euclidean dan range yang mengindikasikan rentang jarak dimana korelasi spasial error mulai berkurang secara signifikan dan dinyatakan dalam satuan km. Korelasi spasial bernilai 1 jika jarak antar lokasi d adalah 0 dan makin menurun hingga bernilai 0,5 saat d mencapai $3r$ (Cressie, 1993). Persamaan (2.36) mengindikasikan dependensi error dapat diidentifikasi melalui variogram eksponensial


$$\gamma(\mathbf{d}) = \rho^2 + \sigma^2 \left(1 - \exp\left(-\frac{\mathbf{d}}{r}\right)\right) \quad (2.37)$$

dimana \mathbf{d} pada persamaan (2.37) merupakan $\|\mathbf{s}_i - \mathbf{s}_j\|$ yang menyatakan jarak Euclidean antara himpunan pasangan lokasi \mathbf{s}_i dan \mathbf{s}_j .

Untuk mendapatkan estimasi parameter, terdapat dua tahap yang dilakukan berdasarkan pendekatan menyerupai *maximum likelihood*, yaitu:

1. Mengestimasi koefisien β_0 dan β_1 menggunakan regresi linier sederhana dan menghitung residual model GOP.
2. Residual model GOP kemudian menjalani proses *binning* (pengelompokan) untuk mengestimasi parameter variogram ρ^2, σ^2 dan r . Metode yang digunakan untuk estimasi adalah kuadrat terkecil terboboti atau *weighted least squares* WLS berdasarkan Cressie (1993), dengan bobot sebesar banyaknya observasi dalam kelompok-kelompok *binning*.

Setelah estimasi ρ^2, σ^2 dan r diperoleh, maka dilakukan penyatuan informasi semivarians empiris dan teoritis ke dalam semivariogram, seperti yang diilustrasikan pada Gambar 2.1.



Gambar 2.1 Semivariogram Pra-Simulasi GOP (Berrocal *et al.*, 2007)

Gambar 2.1 menunjukkan bahwa semi-variants, yang mendeskripsikan kontinuitas spasial, makin tidak terlihat nyata dan bernilai relatif stabil ketika jarak menyentuh *range* r tertentu. Besarnya semi-variants atau disebut juga semivariogram pada *range* tersebut disebut *sill*. Kedua parameter tersebut, termasuk *nugget*, memiliki kontribusi terhadap hasil prakiraan cuaca dan dapat pula dipakai untuk menghasilkan prakiraan cuaca pada stasiun pengamatan yang tidak dilibatkan dalam pemodelan, yang disebut sebagai metode *kriging*. Kriging sendiri didasari dari persamaan linear terboboti dimana bobot bernilai makin besar jika jarak antara kedua lokasi makin dekat, begitu pula sebaliknya (Cressie, 1993).

2.8 Dependensi Spasial

Dalam analisis yang melibatkan data dari beragam lokasi, terdapat kecenderungan bahwa lokasi yang saling berdekatan memiliki asosiasi dan/atau yang lebih tinggi daripada lokasi yang saling berjauhan (Anselin, 1988). Keadaan yang demikian dapat disebut sebagai dependensi spasial. Salah satu indikator yang dapat digunakan untuk mengetahui dependensi spasial pada data yang diteliti adalah Moran's I yang didasari dari suatu matrik jarak \mathbf{W} .

Matrik jarak \mathbf{W} adalah matrik yang mendefinisikan kedekatan antara dua lokasi. Terdapat beberapa cara untuk mendefinisikan kedekatan antara dua lokasi, diantaranya dengan *cut-off distance*. Pendekatan ini menggunakan suatu jarak tertentu (dalam km, meter, mil, dan sebagainya) yang diperkirakan masih memberikan pengaruh antara dua lokasi. Jika jarak antar lokasi berada di bawah *cut-off distance*, maka elemen bersesuaian pada matrik \mathbf{W} diberi nilai 1, sebaliknya diberi nilai 0 (Anselin, 1988).

Berdasarkan Cliff dan Ord (1981), Moran's I adalah indikator yang mengukur dependensi spasial secara global dimana nilainya berkisar antara -1 hingga 1, terutama jika matrik \mathbf{W} yang digunakan adalah hasil standarisasi. Jika Moran's I bernilai positif, maka lokasi yang berdekatan diindikasikan memiliki keterkaitan, namun sebaliknya jika I bernilai negatif. Persamaan (2.38) merupakan Moran's I berdasarkan matrik jarak \mathbf{W} berukuran $s \times s$ yang distandarkan dimana \mathbf{x} adalah vektor observasi berukuran $s \times 1$.

$$I = \frac{(\mathbf{x} - \bar{\mathbf{x}})' \mathbf{W} (\mathbf{x} - \bar{\mathbf{x}})}{(\mathbf{x} - \bar{\mathbf{x}})' (\mathbf{x} - \bar{\mathbf{x}})} \quad (2.38)$$

Dalam Cliff dan Ord (1981), signifikansi Moran's I dapat diuji dengan menggunakan pendekatan normal. Pada uji ini, hipotesis nol (H_0) yang berlaku adalah tidak terdapat otokorelasi spasial. Statistik uji yang digunakan dinyatakan dalam persamaan (2.39),

$$Z(I) = \frac{I - \hat{E}(I)}{\sqrt{\widehat{\text{var}}(I)}} \sim N(0,1) \quad (2.39)$$

dengan

$$\hat{E}(I) = -\frac{1}{n-1}; \widehat{\text{var}}(I) = \frac{n^2 S_1 - n S_2 + 3 S_0^2}{(n^2 - 1) S_0^2} - \left(\hat{E}(I) \right)^2 \text{ dan berlaku pula bagi } \widehat{\text{var}}(I),$$

$$S_0 = \sum_{i=1}^n \sum_{j=1}^n w_{ij}; S_1 = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (w_{ij} + w_{ji})^2; S_2 = \sum_{i=1}^n \left(\sum_{j=1}^n w_{ij} + \sum_{j=1}^n w_{ji} \right)^2.$$

Keputusan untuk menolak H_0 diambil jika $|Z(I)| > z_{1-\alpha/2}$ dimana $z_{1-\alpha/2}$ adalah kuantil $\left(1 - \frac{\alpha}{2}\right) \times 100\%$ distribusi normal standar.

2.9 Evaluasi Kebaikan Model Kalibrasi

Pada umumnya, kebaikan model untuk prakiraan cuaca dapat dievaluasi berdasarkan beragam perspektif. Namun, evaluasi untuk model kalibrasi yang memanfaatkan ensemble sedikit berbeda daripada model-model prakiraan cuaca lainnya. Definisi kalibrasi adalah konsistensi statistik yang terbentuk antara observasi dan hasil ramalan metode ensemble, misal BMA. Suatu prakiraan dikatakan terkalibrasi jika kejadian yang diramalkan akan terjadi dengan probabilitas 70%, maka dalam jangka panjang probabilitas kejadian itu di masa mendatang berada pada kisaran 70%, misal 69% atau 71% (Raftery *et al.*, 2005).

Kebaikan model tidak hanya dievaluasi dari error prakiraan yang diperoleh, tetapi juga koreksi bias dan ketajaman prakiraan ensemble terhadap observasi (Feldmann, 2012). Ketajaman adalah kekuatan penyebaran distribusi prediktif, yang mengindikasikan bahwa makin tajam suatu distribusi prediktif yang terkalibrasi, maka estimator makin stabil (mampu mengoreksi bias lebih baik)

dan performa ramalan semakin baik. Misal diketahui bahwa suhu udara pada tanggal 1 Januari 2014 adalah 26,7° C, maka interval prediktif (26° C, 27° C) dinilai lebih tajam daripada interval prediktif (25° C, 28° C). Menurut Möller (2014), *Root Mean Square Error* (RMSE) adalah indikator yang cukup untuk menilai kualitas prakiraan. Sementara, koreksi bias dapat dievaluasi melalui *coverage* dan *Continuous rank probability score* (CRPS).

2.9.1 Root Mean Square Error (RMSE)

RMSE merupakan salah satu indikator yang digunakan untuk mengevaluasi kualitas prakiraan cuaca, khususnya untuk data *testing*. RMSE merupakan akar kuadrat dari MSE, yaitu rata-rata jumlah kuadrat dari selisih antara nilai prakiraan dan observasi. Persamaan (2.40) merupakan formula untuk menghitung RMSE

$$\text{RMSE} = \sqrt{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.40)$$

dengan n adalah banyak observasi. Kelebihan RMSE terletak pada satuan perhitungan yang sama dengan satuan variabel, sehingga mudah untuk dijadikan sebagai alat perbandingan ketimbang MSE atau MAE. Namun, jika terdapat pencilan yang cukup banyak pada observasi yang diamati, RMSE cenderung kurang *robust* terhadap keadaan tersebut (Anggraeni, 2013).

2.9.2 Coverage

Ketajaman dari prakiraan ensemble dapat diidentifikasi melalui *coverage*, yaitu indikator yang menggunakan lebar ensemble *range* sebagai tolak ukur. Jika observasi berada dalam *ensemble range*, maka observasi tersebut dikatakan berada dalam *coverage*. Coverage dihitung dari persentase banyaknya observasi yang berada dalam *ensemble range*, khususnya observasi yang berada dalam periode *testing* atau *out-sample* (Raftery *et al.*, 2005).

Agar memiliki pembandingan antara nilai observasi dan ramalan dari ensemble dengan m anggota, maka standar *coverage* dihitung berdasarkan $\frac{M-1}{M+1} \times 100\%$. Jadi, standar *coverage* bergantung pada banyaknya anggota ensemble yang dilibatkan dalam pemodelan. Makin banyak anggota ensemble, maka *coverage* yang harus dicapai juga makin tinggi (Feldmann, 2012).

Coverage umumnya digunakan untuk mengidentifikasi apakah prakiraan ensemble masih bersifat *underdispersive* atau *overdispersive*. Jika *coverage* data jauh lebih rendah daripada standar *coverage*, maka prakiraan ensemble masih bersifat *underdispersive*, namun sebaliknya jika *coverage* data lebih tinggi daripada standar *coverage*, maka prakiraan ensemble diindikasikan bersifat *overdispersive*. Prakiraan ensemble yang terkalibrasi terlihat dari *coverage* data yang nilainya mendekati standar *coverage*.

2.9.3 Continuous Rank Probability Score (CRPS)

Salah satu bagian terpenting untuk mengevaluasi kebaikan model prakiraan cuaca, baik deterministik atau probabilistik, adalah melalui *scoring rules*. RMSE yang diuraikan pada subbab 2.9.1 merupakan salah satu *scoring rules*. Selain itu, CRPS juga dapat memverifikasi model prakiraan dari segi tingkat koreksi bias dan ketajaman yang tercapai. Ketajaman mengindikasikan bahwa PDF prediktif model terkalibrasi mampu memperbaiki PDF prediktif model sebelum kalibrasi, yaitu interval PDF model kalibrasi lebih sempit ketimbang sebelum dikalibrasi. Makin sempit interval yang diperoleh dimana sebagian besar nilai observasi berada dalam interval tersebut, maka hasil prakiraan dikatakan reliabel (Feldmann, 2012).


CRPS dirumuskan dalam persamaan (2.41),

$$CRPS = \frac{1}{n} \sum_{i=1}^n crps(F_i, y_i) = \frac{1}{n} \sum_{i=1}^n \int_{-\infty}^{\infty} [F_i^{forecast}(y) - F_i^{obs}(y)]^2 dy \quad (2.41)$$

dengan n adalah banyaknya observasi, i adalah periode waktu yang digunakan (jam, harian, bulanan, dan sebagainya), $F_i^{forecast}(y)$ adalah CDF prediktif pada waktu ke- i , dan $F_i^{obs}(y)$ adalah CDF empiris pada waktu ke- i (Anggraeni, 2013).

Khusus untuk $F_i^{obs}(y)$, berlaku bahwa $F_i^{obs}(y) = \begin{cases} 1, & y_{forecast} \geq y_{obs} \\ 0, & y_{forecast} < y_{obs} \end{cases}$.

Makin rendah nilai CRPS, dalam hal ini mendekati 0, maka model tersebut makin baik dan reliabel dalam melakukan prakiraan cuaca. Gambar 2.2 merupakan CDF untuk prakiraan cuaca pada suatu waktu i dengan nilai observasi sebesar 5 satuan, dengan sumbu horizontal menyatakan rentang nilai prakiraan cuaca yang mungkin, dan sumbu vertikal menyatakan probabilitas dari CDF.



Gambar 2.2 CDF Observasi dan Prakiraan pada Waktu ke- i

Berdasarkan Gambar 2.2, terdapat dua CDF prakiraan yang diperoleh dari regresi PLS (berwarna merah), sementara CDF lainnya (berwarna biru) diperoleh dari regresi PCR. Diasumsikan kedua CDF tersebut mengikuti distribusi normal. Jika diperhatikan, terlihat bahwa CDF PCR lebih landai ketimbang CDF PLS. Hal ini mengindikasikan varians prakiraan PLS lebih kecil daripada varians prakiraan PCR. Meskipun observasi (CDF hitam) berada dalam interval prediktif kedua metode, namun interval PLS ternyata lebih sempit. Berdasarkan persamaan (2.41), hal ini mengakibatkan CRPS PLS menjadi lebih rendah daripada CRPS PCR yang mengindikasikan interval prediktif PLS lebih presisi atau reliabel daripada interval PCR, meskipun kedua metode memiliki akurasi yang hampir sama.

2.10 Numerical Weather Prediction (NWP)

Numerical Weather Prediction (NWP) adalah sekumpulan kode pemrograman yang mempresentasikan secara numerik persamaan-persamaan atmosfer berdasarkan sifat-sifat fisika dinamis, digunakan untuk memprediksi kondisi atau status NWP atmosfer yang akan datang dengan menggunakan kemampuan komputer yang tinggi (Idowu dan Rautenbach, 2009). Prakiraan cuaca dirumuskan dengan menyelesaikan persamaan pergerakan atmosfer. Persamaan-persamaan tersebut meliputi persamaan non-linier *time-dependent differential parsial* angin, temperatur, kelembapan dan tekanan.

NWP diukur dalam domain lokasi atau resolusi grid yang tinggi, berkisar antara 7 – 60 km, sehingga NWP diharapkan dapat menangkap fenomena cuaca yang sedang terjadi di domain tersebut. Namun, kondisi cuaca skala kecil atau skala lokal kurang terepresentasikan dengan baik. Oleh karena itu, luaran NWP memiliki sifat bias dalam meramalkan kondisi cuaca lokal sebab diukur pada domain yang tinggi. Selain itu, luaran NWP juga bersifat deterministik dan tidak bisa secara lengkap menjelaskan cuaca secara stokastik, sehingga perlu diterapkannya pemrosesan secara statistik (*statistical post-processing*) agar mampu menjelaskan ketidakpastian tersebut (Wilks, 2006).

Conformal Cubic Atmospheric Model (CCAM) adalah salah satu model aplikasi yang menghasilkan produk NWP. CCAM pertama kali dikembangkan oleh CSIRO (*Commonwealth Scientific and Industrial Research Organization*) Australia yang sebelumnya mengembangkan *Division of Atmospheric Research Limited Area Model* (DARLAM), kemudian CCAM diterapkan di Indonesia pada tahun 2007. Input yang diperlukan oleh CCAM adalah AVN/GFS. AVN/GFS adalah model spektral untuk prediksi cuaca global yang dijalankan oleh *National Centers for Environmental Prediction* (NCEP). Model ini dapat memprediksi keadaan cuaca seluruh dunia hingga 2 minggu ke depan (BMKG, 2011). BMKG sendiri mulai mengembangkan penelitian tentang CCAM pada tahun 2007-2009.

Menurut Raible, Bishop, dan Fraedrich (1998) dalam Arfianto (2008), secara umum model-model NWP cukup baik dalam peramalan jangka pendek (*short-term forecasting*) hingga 24 jam ke depan. NWP dicatat pada grid (kombinasi lintang-bujur) tertentu dengan deskripsi sebagai berikut.


1. Parameter NWP diantaranya *Surface Pressure tendency* (dpsdt), *Water Mixing Ratio* (mixr), *Geopotential Height* (Z), *Temperature* (T), *Relative Humidity* (RH), komponen U-V (komponen angin timur dan barat), *Mean Sea Level Pressure* (psl), *Vertical Velocity* (omega), *Maximum Screen Temperature* (tmaxscr), *Minimum Screen Temperature* (tminscr).
2. Level tekanan: 1000 mb, 950 mb, 925 mb, 900 mb, 850 mb, 800 mb, 700 mb, 600 mb, 500 mb, 400 mb, 350 mb, 300 mb dan 200mb. Level ketinggian: permukaan, 2 meter, dan 10 meter. NWP diukur pada level tekanan tertentu,

dan dapat diukur pada level ketinggian : permukaan laut, 2 meter, dan 10 meter di atas permukaan laut.

3. Ramalan NWP dilakukan setiap 6 jam sekali, yaitu pada jam ke-00, 06, 12, 18, 24, 36, 42, 48, 54, 60, 66, dan 72.
4. Resolusi: grid lintang bujur $0,5^\circ \times 0,5^\circ$ ($55,5 \times 55,5$) km^2 . NWP diukur pada grid poin yang luas dengan ukuran lintang-bujur tertentu.

Grid merupakan proyeksi keadaan bumi dan atmosfer di atasnya yang berbentuk 3 dimensi. Grid pada umumnya menyerupai persegi atau persegi panjang, walaupun pada prosesnya grid dapat berbentuk segitiga atau segienam. Prakiraan NWP untuk tiap komponen cuaca, seperti suhu permukaan, kecepatan angin, tekanan udara, dapat dikeluarkan oleh tiap grid. Resolusi grid diatur sedemikian rupa oleh otoritas meteorologi yang disesuaikan dengan kepentingan peramalan jangka pendek hingga jangka panjang. Semakin tinggi resolusi yang digunakan, maka NWP akan menghasilkan ramalan jangka pendek yang lebih akurat, namun memakan waktu komputasi yang lebih lama (Wilks, 2006).

Hasil dari prediksi cuaca dengan NWP pada resolusi tinggi di suatu tempat (grid) seringkali menghasilkan bias yang besar, terutama untuk wilayah dengan topografi dan tutupan vegetasi yang kompleks. Gambar 2.3 mengilustrasikan perbedaan kondisi cuaca riil di suatu wilayah dengan topografi yang beragam (a) dan grid model NWP (b).



Gambar 2.3 Ilustrasi Kondisi Cuaca (a) Dunia Nyata dan (b) NWP (Linacre dan Geerts, 2003)

Gambar 2.3 menunjukkan bahwa terdapat perbedaan kondisi cuaca yang signifikan antara dunia nyata dan model NWP. Hal ini tidak mengherankan sebab kondisi riil permukaan bumi dan atmosfer di suatu tempat bervariasi, baik dalam domain spasial (daerah), temporal (waktu) maupun elevasi (ketinggian).

Sayangnya, model NWP justru belum menangkap fenomena di atas, padahal suatu area yang luas dipandang memiliki keragaman topografi dan keadaan atmosfer yang cenderung heterogen. Berdasarkan kenyataan ini, dapat dikatakan bahwa luaran NWP belum menjelaskan keragaman cuaca di wilayah yang lebih heterogen dari segi keadaan alam (Sari, 2013).


NWP menyederhanakan dan menyamaratakan kondisi permukaan agar homogen dengan merepresentasikan permukaan bumi ke dalam rangkaian titik grid. Dengan demikian, model NWP tidak merepresentasikan lokasi dan variabel yang dibutuhkan. Padahal, hubungan statistik justru dapat dibangun berdasarkan informasi yang dihasilkan NWP dan nilai prakiraan yang dimaksud. Informasi NWP yang digunakan bersamaan dengan metode statistik memungkinkan untuk mengkuantifikasi dan menjelaskan ketidakpastian dengan menghubungkannya berdasarkan kondisi prediksi yang berbeda atau probabilistik (Wilks, 2006).

2.11 Sistem Prediksi Ensemble

Menurut Park (2006), sistem prediksi ensemble atau EPS (*ensemble prediction system*) adalah suatu sistem yang terdiri dari beberapa kombinasi model yang mengolah luaran tunggal deterministik (*deterministic forecast*) dalam waktu bersamaan. Salah satu contoh dari model prakiraan tunggal deterministik yang lazim dikembangkan oleh banyak negara adalah *Numerical Weather Prediction* (NWP). Model prediksi ensemble cukup banyak digunakan dalam bidang iklim dan sains atmosfer dimana hasil luaran model ini secara operasional memiliki kualitas yang cukup baik, meskipun kurang reliabel karena masih banyak nilai observasi yang jauh berada di luar *ensemble range* (*coverage* cenderung rendah). Prediksi ensemble dapat dieksekusi dengan beragam cara, antara lain dengan penggunaan model yang berbeda dan resolusi yang beragam, mulai resolusi rendah hingga resolusi tinggi (Viney, Croke, Breuer, Bormann, Bronstert, Freed, Graff, Hubrechts, Huisman, Jakeman, Kite, Lanini, Leavesley, Lettenmaier, Lindstrom, Seibert, Sivapalan, dan Willem, 2006). Selain itu, prediksi ensemble juga dapat dikonstruksi dengan penggunaan syarat awal (*initial condition*) perturbasi yang berbeda, sehingga akan membentuk beberapa anggota ensemble untuk prakiraan komponen cuaca tertentu.

Meskipun prediksi yang dihasilkan NWP saat ini makin mendekati observasi, namun tidak menutup kemungkinan diperoleh bias prediksi yang tinggi akibat keadaan atmosfer yang selalu dinamis dan berfluktuasi. Dalam Viney *et al.* (2005), penggunaan metode ensemble dalam prakiraan cuaca/iklim mampu memiliki performa yang lebih baik daripada NWP. Selain itu, Demeritt, Cloke, Pappenberger, Thielen, Bartholmes, dan Ramos (2007) menyimpulkan bahwa prakiraan ensemble lebih sesuai dengan kondisi riil. Namun demikian, terdapat dua sumber ketidakpastian yang dipertimbangkan agar model ensemble menghasilkan prakiraan yang reliabel dan tajam, yaitu syarat awal (*initial condition*) dan konstruksi model. Berdasarkan Anggraeni (2013), prakiraan ensemble diawali perumusan deterministik yang terdiri dari beragam variabel cuaca dan iklim (temperatur permukaan, tekanan udara, kelembapan, dan lain-lain) dimana masing-masing memiliki *initial condition* yang berlainan, kemudian disimulasikan secara iteratif. Pada tahap konstruksi model, terdapat beberapa teknik yang dapat digunakan, antara lain skema perturbasi. Skema ini mengurangi unsur ketidakpastian model melalui modifikasi nilai antar anggota ensemble. Dengan demikian, prakiraan ensemble terkalibrasi dapat mendekati nilai observasi dan sesuai dengan kondisi riil yang sedang terjadi.

Saat ini, tidak banyak negara yang mampu dan konsisten dalam mengembangkan sistem prediksi ensemble (EPS) karena diperlukan sumber daya yang berkualitas, biaya yang besar dan teknologi yang canggih untuk membangkitkan data ensemble per satuan waktu ke depan (*lead time ahead*). Semakin singkat *lead* prediksi, maka proses komputasi dan spesifikasi pola atmosfer yang dilakukan akan makin kompleks (Demeritt *et al.*, 2007). Beberapa otoritas yang menerapkan sistem prediksi ensemble untuk komponen cuaca, diantaranya *National Centers for Environmental Prediction (NCEP) of US*, *Météo-France*, *European Centre for Medium-Range Weather Forecast (ECMWF)*, dan *Japan Meteorological Agency*. Gambar 2.4 adalah ilustrasi prediksi ensemble untuk elemen cuaca temperatur untuk wilayah Jerman yang dikeluarkan COSMO-DE, otoritas Jerman yang memiliki kewenangan mirip dengan BMKG Indonesia.



Gambar 2.4 Prediksi 2 Model Ensemble untuk Temperatur Wilayah Jerman 5 Januari 2011 (Feldmann, Scheuerer, dan Thorarinsdottir, 2015)

Di Indonesia, sistem ini pernah dikembangkan oleh BMKG selama beberapa tahun, namun prakiraan yang dihasilkan tidak lebih baik dibandingkan beberapa metode lainnya. Biaya yang tinggi juga menjadi kendala bagi BMKG untuk menggunakan sistem prediksi ensemble secara berkelanjutan.

2.12 Suhu / Temperatur

Suhu atau temperatur merupakan suatu ukuran yang menyatakan termalitas beberapa sistem baik secara parsial maupun integral atau dengan kata lain ukuran panas atau dinginnya suatu benda (Quinn, 1990). Sementara, untuk lingkup yang lebih spesifik, suhu atmosfer merupakan ukuran suhu pada berbagai tingkatan di atmosfer Bumi yang dapat dipengaruhi radiasi matahari, kelembapan serta ketinggian, sehingga mengakibatkan adanya hubungan kompleks antara biosfer, litosfer dan atmosfer. Energi secara konstan berpindah dari permukaan ke udara di atasnya.

Menurut Tanudidjaja (1993), keadaan suhu atmosfer pada suatu tempat di permukaan bumi ditentukan oleh beragam faktor, seperti lama penyinaran matahari, kemiringan sinar matahari, keadaan awan, dan keadaan permukaan bumi. Misal semakin lama matahari memancarkan sinarnya di suatu daerah, maka semakin banyak panas yang diterima oleh daerah tersebut. Keadaan atmosfer yang cerah sepanjang hari menyebabkan temperatur di daerah tersebut lebih panas daripada jika kondisi cuaca pada hari itu berawan atau hujan sejak pagi.


BAB III

METODE PENELITIAN

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG), yaitu data observasi suhu udara (suhu maksimum dan suhu minimum) harian untuk periode 1 Januari 2009 sampai 31 Desember 2010 atau selama 708 hari. Untuk membentuk model BMA dan GOP, diperlukan data harian NWP model CCAM pada periode yang sama dengan observasi. Stasiun pengamatan yang menjadi fokus dalam penelitian ini ialah 8 stasiun meteorologi (stamet) di Jabotabek, yaitu stamet Kemayoran, Tanjung Priok, Cengkareng, Pondok Betung, Curug, Tangerang, Citeko, dan Dermaga, yang ditunjukkan pada Gambar 3.1.

Seluruh stasiun meteorologi tersebut dipilih karena data histori pengukuran cuaca pada stasiun tersebut cukup baik dan lengkap. Selain itu, beberapa stasiun tersebut dianggap mewakili kota Jakarta (Kemayoran), kota Tangerang (Tangerang), kota Tangerang Selatan (Pondok Betung) dan kabupaten Bogor (Citeko). Karakteristik atmosfer yang dinamis memperbesar kemungkinan bahwa kondisi cuaca di DKI Jakarta juga dipengaruhi kondisi cuaca di daerah sekitar, yaitu Bogor dan Tangerang.



Gambar 3.1 Lokasi Stasiun Meteorologi (BMKG, 2011)

3.2 Variabel Penelitian

Variabel respon yang digunakan dalam penelitian ini adalah data observasi cuaca untuk suhu udara (Celcius), yaitu suhu maksimum (T_{MAKS}) dan suhu minimum (T_{MIN}). Terdapat perbedaan pada variabel prediktor yang digunakan oleh kedua metode. Untuk metode BMA, prediktor yang digunakan adalah prakiraan suhu udara yang dimodelkan dengan PLS, PCR, dan regresi Ridge. Sementara untuk metode GOP, prediktor yang digunakan adalah luaran NWP untuk suhu udara, yaitu $tmaxscr$ dan $tminscr$. Prediktor BMA diperoleh dari luaran parameter NWP yang direduksi menggunakan PCA.

Parameter NWP CCAM ditentukan oleh ahli meteorologi. Selain itu, BMKG dalam beberapa tahun terakhir sudah mengadakan penelitian yang intensif dengan CSIRO Australia sebagai lembaga yang mengembangkan CCAM. Parameter NWP CCAM untuk metode BMA dan GOP disajikan pada Tabel 3.1.


Tabel 3.1 Parameter NWP CCAM yang Digunakan

Parameter NWP (kode)	Level	X	Satuan
<i>Surface Pressure Tendency</i> (dpsdt)	Permukaan	X_1	hPa
<i>Water Mixing Ratio</i> (mix)	1, 2, 4	X_2, X_3, X_4	g/kg
<i>Vertical Velocity</i> (omega)	1, 2, 4	X_5, X_6, X_7	knot
<i>PBL depth</i> (pblh)	Permukaan	X_8	meter
<i>Surface Pressure</i> (ps)	Permukaan	X_9	hPa
<i>Mean Sea Level Pressure</i> (psl)	Permukaan	X_{10}	hPa
<i>Screen Mixing Ratio</i> (qgscm)	Permukaan	X_{11}	g/kg
<i>Relative Humidity</i> (rh)	1, 2, 4	X_{12}, X_{13}, X_{14}	%
<i>Precipitation</i> (rnd)	Permukaan	X_{15}	mm
<i>Temperature</i>	1, 2, 4	X_{16}, X_{17}, X_{18}	Celcius
<i>Maximum Screen Temperature</i> (tmaxscr)	Permukaan	X_{19}	Celcius
<i>Minimum Screen Temperature</i> (tminscr)	Permukaan	X_{20}	Celcius
<i>Pan Temperature</i> (tpan)	Permukaan	X_{21}	Celcius
<i>Screen Temperature</i> (tscrn)	Permukaan	X_{22}	Celcius
<i>Zonal Wind</i> (u)	1, 2, 4	X_{23}, X_{24}, X_{25}	knot
<i>Friction Velocity</i> (ustar)	Permukaan	X_{26}	m/sec
<i>Meridional Wind</i> (v)	1, 2, 4	X_{27}, X_{28}, X_{29}	knot
<i>Geopotential Height</i> (zg)	1, 2, 4	X_{30}, X_{31}, X_{32}	meter

(Sumber : BMKG, 2011)

Parameter NWP yang akan digunakan di tiap stamet adalah sebanyak 18 parameter dengan 11 parameter diukur pada level permukaan, yaitu pada ketinggian ± 2 m di atas permukaan laut. Sementara, 7 parameter lainnya diukur pada tiga level tekanan yang berbeda, yaitu level 1, 2 dan 4, dimana level 1 saat tekanan 1000 mb (milibar), level 2 saat tekanan 950 mb dan level 4 saat tekanan

850 mb. Jadi, total parameter yang digunakan sebanyak $(11 + 21)$ atau 32 parameter karena 7 parameter yang diukur pada 3 level berbeda akan menghasilkan (7×3) parameter atau 21 parameter. Kemudian, tiap 32 parameter diestimasi pada sembilan grid (3×3) pengukuran yang terdekat dari lokasi stasiun pengamatan. Proyeksi pengukuran parameter NWP dalam grid 3×3 diilustrasikan oleh Gambar 3.2.



Gambar 3.2 Proyeksi Pengukuran NWP

Lingkaran merah di tengah kotak pada Gambar 3.2 menunjukkan grid terdekat dari stasiun Kemayoran (diilustrasikan oleh balon udara), sedangkan lingkaran berwarna hitam merupakan kombinasi grid di sekitar stasiun pengamatan. Jadi, tiap stasiun yang diamati memiliki total parameter sebanyak (32×9) parameter atau 288 parameter. Oleh karena itu, tiap parameter akan mempunyai korelasi yang kuat dengan dirinya sendiri karena diukur pada 9 grid yang saling berdekatan. Antar parameter NWP diduga juga saling berkorelasi sebab kecenderungan hubungan antar tiap komponen cuaca yang tinggi.

Definisi parameter NWP yang diolah sebagai *input* prediktor adalah sebagai berikut (NOAA, 2015).

1. *Surface Pressure Tendency* atau kecenderungan tekanan permukaan merupakan suatu indikasi arah dan intensifikasi dari distorsi siklon.
2. *Water Mixing Ratio* adalah rasio jumlah uap air di udara pada ketinggian tertentu.
3. *Vertical Velocity* adalah kecepatan angin vertikal yang diukur.
4. PBL (*Planetary Boundary Layer*) *depth* merupakan suatu skala ketinggian yang mendeskripsikan vertikal *mixing* dari turbulensi dan konveksi awan kumululus.

5. *Surface Pressure* atau tekanan permukaan diukur berdasarkan tekanan gaya pada permukaan dengan luas tertentu.
6. *Mean Sea Level Pressure* adalah suhu rata-rata di atas permukaan laut.
7. *Screen Mixing Ratio* adalah rasio jumlah uap air di udara pada level permukaan, yaitu 2 meter di atas permukaan laut.
8. *Relative Humidity* atau kelembapan adalah konsentrasi uap air di udara.
9. *Precipitation* adalah setiap produk dari kondensasi uap air di atmosfer yang jatuh karena gravitasi.
10. *Temperature* atau suhu udara adalah derajat panas dan dingin udara di atmosfer, yang memiliki hubungan berbanding terbalik dengan tekanan udara.
11. *Maximum Screen Temperature* merupakan suhu tertinggi yang terukur pada grid-grid.
12. *Minimum Screen Temperature* merupakan suhu terendah yang terukur pada grid-grid.
13. *Pan temperature* adalah suhu udara di atas sumber air yang terdekat dengan grid-grid.
14. *Screen temperature* adalah derajat panas dan dingin udara pada grid-grid.
15. *Zonal wind* atau angin zonal merupakan komponen angin yang bergerak dengan arah barat-timur.
16. *Friction Velocity* atau kecepatan gesekan adalah bentuk tegangan geser dan dapat ditulis dalam satuan kecepatan.
17. *Meridional Wind* atau angin meridian merupakan komponen angin yang bergerak dengan arah utara-selatan.
18. *Geopotential Height* adalah koordinat vertikal yang direferensikan ke permukaan laut bumi dengan menggunakan variasi gravitasi dengan garis lintang dan ketinggian.

Berdasarkan Tabel 3.1 dan Gambar 3.2, diperoleh p sebanyak 32 parameter dan r sebanyak 9 grid. Tabel 3.2 adalah ilustrasi struktur data yang akan diolah dengan metode BMA untuk salah satu stamet s yang terletak pada koordinat lintang-bujur tertentu, dengan respon Y_t adalah observasi suhu udara pada hari ke- t dan elemen variabel $X_{p,r,t}$ merupakan luaran NWP parameter p grid ke- r untuk hari ke- t .

Tabel 3.2 Struktur Data untuk Metode BMA pada Stasiun s

Tanggal	Y	X_1				X_2				...	X_p			
		$X_{1,1}$	$X_{1,2}$...	$X_{1,9}$	$X_{2,1}$	$X_{2,2}$...	$X_{2,9}$...	$X_{p,1}$	$X_{p,2}$...	$X_{p,r}$
1/1/2009	Y_1	$X_{1,1,1}$	$X_{1,2,1}$...	$X_{1,9,1}$	$X_{2,1,1}$	$X_{2,2,1}$...	$X_{2,9,1}$...	$X_{p,1,1}$	$X_{p,2,1}$...	$X_{p,r,1}$
2/1/2009	Y_2	$X_{1,1,2}$	$X_{1,2,2}$...	$X_{1,9,2}$	$X_{2,1,2}$	$X_{2,2,2}$...	$X_{2,9,2}$...	$X_{p,1,2}$	$X_{p,2,2}$...	$X_{p,r,2}$
3/1/2009	Y_3	$X_{1,1,3}$	$X_{1,2,3}$...	$X_{1,9,3}$	$X_{2,1,3}$	$X_{2,2,3}$...	$X_{2,9,3}$...	$X_{p,1,3}$	$X_{p,2,3}$...	$X_{p,r,3}$
4/1/2009	Y_4	$X_{1,1,4}$	$X_{1,2,4}$...	$X_{1,9,4}$	$X_{2,1,4}$	$X_{2,2,4}$...	$X_{2,9,4}$...	$X_{p,1,4}$	$X_{p,2,4}$...	$X_{p,r,4}$
5/1/2009	Y_5	$X_{1,1,5}$	$X_{1,2,5}$...	$X_{1,9,5}$	$X_{2,1,5}$	$X_{2,2,5}$...	$X_{2,9,5}$...	$X_{p,1,5}$	$X_{p,2,5}$...	$X_{p,r,5}$
6/1/2009	Y_6	$X_{1,1,6}$	$X_{1,2,6}$...	$X_{1,9,6}$	$X_{2,1,6}$	$X_{2,2,6}$...	$X_{2,9,6}$...	$X_{p,1,6}$	$X_{p,2,6}$...	$X_{p,r,6}$
7/1/2009	Y_7	$X_{1,1,7}$	$X_{1,2,7}$...	$X_{1,9,7}$	$X_{2,1,7}$	$X_{2,2,7}$...	$X_{2,9,7}$...	$X_{p,1,7}$	$X_{p,2,7}$...	$X_{p,r,7}$
8/1/2009	Y_8	$X_{1,1,8}$	$X_{1,2,8}$...	$X_{1,9,8}$	$X_{2,1,8}$	$X_{2,2,8}$...	$X_{2,9,8}$...	$X_{p,1,8}$	$X_{p,2,8}$...	$X_{p,r,8}$
9/1/2009	Y_9	$X_{1,1,9}$	$X_{1,2,9}$...	$X_{1,9,9}$	$X_{2,1,9}$	$X_{2,2,9}$...	$X_{2,9,9}$...	$X_{p,1,9}$	$X_{p,2,9}$...	$X_{p,r,9}$
10/1/2009	Y_{10}	$X_{1,1,10}$	$X_{1,2,10}$...	$X_{1,9,10}$	$X_{2,1,10}$	$X_{2,2,10}$...	$X_{2,9,10}$...	$X_{p,1,10}$	$X_{p,2,10}$...	$X_{p,r,10}$
11/1/2009	Y_{11}	$X_{1,1,11}$	$X_{1,2,11}$...	$X_{1,9,11}$	$X_{2,1,11}$	$X_{2,2,11}$...	$X_{2,9,11}$...	$X_{p,1,11}$	$X_{p,2,11}$...	$X_{p,r,11}$
12/1/2009	Y_{12}	$X_{1,1,12}$	$X_{1,2,12}$...	$X_{1,9,12}$	$X_{2,1,12}$	$X_{2,2,12}$...	$X_{2,9,12}$...	$X_{p,1,12}$	$X_{p,2,12}$...	$X_{p,r,12}$
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
25/12/2010	Y_{702}	$X_{1,1,702}$	$X_{1,2,702}$...	$X_{1,9,702}$	$X_{2,1,702}$	$X_{2,2,702}$...	$X_{2,9,702}$...	$X_{p,1,702}$	$X_{p,2,702}$...	$X_{p,r,702}$
26/12/2010	Y_{703}	$X_{1,1,703}$	$X_{1,2,703}$...	$X_{1,9,703}$	$X_{2,1,703}$	$X_{2,2,703}$...	$X_{2,9,703}$...	$X_{p,1,703}$	$X_{p,2,703}$...	$X_{p,r,703}$
27/12/2010	Y_{704}	$X_{1,1,704}$	$X_{1,2,704}$...	$X_{1,9,704}$	$X_{2,1,704}$	$X_{2,2,704}$...	$X_{2,9,704}$...	$X_{p,1,704}$	$X_{p,2,704}$...	$X_{p,r,704}$
28/12/2010	Y_{705}	$X_{1,1,705}$	$X_{1,2,705}$...	$X_{1,9,705}$	$X_{2,1,705}$	$X_{2,2,705}$...	$X_{2,9,705}$...	$X_{p,1,705}$	$X_{p,2,705}$...	$X_{p,r,705}$
29/12/2010	Y_{706}	$X_{1,1,706}$	$X_{1,2,706}$...	$X_{1,9,706}$	$X_{2,1,706}$	$X_{2,2,706}$...	$X_{2,9,706}$...	$X_{p,1,706}$	$X_{p,2,706}$...	$X_{p,r,706}$
30/12/2010	Y_{707}	$X_{1,1,707}$	$X_{1,2,707}$...	$X_{1,9,707}$	$X_{2,1,707}$	$X_{2,2,707}$...	$X_{2,9,707}$...	$X_{p,1,707}$	$X_{p,2,707}$...	$X_{p,r,707}$
31/12/2010	Y_{708}	$X_{1,1,708}$	$X_{1,2,708}$...	$X_{1,9,708}$	$X_{2,1,708}$	$X_{2,2,708}$...	$X_{2,9,708}$...	$X_{p,1,708}$	$X_{p,2,708}$...	$X_{p,r,708}$

Sementara, data yang digunakan GOP untuk meramalkan suhu udara memiliki perbedaan struktur dengan data yang diolah dengan BMA. Tabel 3.3 merupakan struktur data untuk stasiun meteorologi s yang berada pada koordinat lintang-bujur tertentu. Respon Y_t adalah observasi suhu udara pada hari ke- t dan variabel $X_{s,t}$ merupakan luaran/prakiraan model NWP untuk suhu udara pada grid terdekat atau grid yang bersesuaian dari stasiun meteorologi s pada hari ke- t .

Tabel 3.3 Struktur Data untuk Metode GOP pada Stasiun s

Tanggal	Y	X_s
1/1/2009	Y_1	$X_{s,1}$
2/1/2009	Y_2	$X_{s,2}$
3/1/2009	Y_3	$X_{s,3}$
4/1/2009	Y_4	$X_{s,4}$
5/1/2009	Y_5	$X_{s,5}$
6/1/2009	Y_6	$X_{s,6}$
7/1/2009	Y_7	$X_{s,7}$
\vdots	\vdots	\vdots
29/12/2010	Y_{706}	$X_{s,706}$
30/12/2010	Y_{707}	$X_{s,707}$
31/12/2010	Y_{708}	$X_{s,708}$

3.3 Kajian Teoritis

Langkah-langkah analisis yang diperlukan untuk mencapai tujuan penelitian teoritis pada Bab 1 adalah sebagai berikut :

1. Mengkaji dan mendapatkan penaksiran parameter BMA melalui tahapan:
 - a. Mengestimasi parameter regresi untuk tiap anggota ensemble m , yaitu $\beta_{0,m}$ dan $\beta_{1,m}$, dengan regresi linier sederhana menggunakan metode *Maximum Likelihood Estimation* (MLE) distribusi normal. Berikut ini merupakan fungsi *likelihood* yang digunakan.

$$L(\beta_{0,m}, \beta_{1,m}, \sigma^2) = \prod_{t=1}^T \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2} \left(y_t - (\beta_{0,m} + \beta_{1,m}f_{mt})\right)^2\right)$$

- b. Mengestimasi parameter bobot untuk tiap anggota ensemble m dan varians menggunakan metode MLE dengan algoritma iteratif *Expectation-Maximization* (EM) dengan langkah berikut.

1) Jika $\boldsymbol{\theta} = [w_1, w_2, \dots, w_M, \sigma^2]^T$, mendapatkan fungsi likelihood untuk

$$\text{data lengkap } L(\boldsymbol{\theta}; \mathbf{y}, \mathbf{z}) = \prod_{t=1}^T \sum_{m=1}^M \mathbf{I}_{(z_t=m)} w_m g_m(y_t | f_{mt}) \text{ dimana } \mathbf{I}_{(z_t=m)}$$

akan bernilai 1 jika $z_t = m$ dan bernilai 0 untuk anggota ensemble lainnya selain m .

2) Untuk iterasi ke- i , mencari nilai ekspektasi dari fungsi log-likelihood terhadap distribusi bersyarat dari \mathbf{Z} diberikan \mathbf{Y} berdasarkan estimasi parameter iterasi ke- i $\boldsymbol{\theta}^{(i)}$. (Tahap *Expectation*)

$$Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)}) = E_{\boldsymbol{\theta}^{(i)}}(\ln L(\boldsymbol{\theta}; \mathbf{y}, \mathbf{z}))$$

Umumnya, nilai awal untuk $\boldsymbol{\theta}$, yaitu $\boldsymbol{\theta}^{(0)}$, didefinisikan sebagai

$$w_m^{(0)} = \frac{1}{M} \text{ dan } \sigma^{2(0)} = \frac{1}{T} \sum_{t=1}^T \sum_{m=1}^M (y_t - f_{mt})^2.$$

3) Memperoleh estimasi parameter $\boldsymbol{\theta}^{(i+1)}$ yang memaksimumkan $Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)})$ dimana $Q(\boldsymbol{\theta}^{(i+1)} | \boldsymbol{\theta}^{(i)}) \geq Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)})$, sehingga diperoleh persamaan (2.31) dengan memanfaatkan observasi laten $z_{mt}^{(i+1)}$ berdasarkan persamaan (2.30). (Tahap *Maximization*)

4) Proses iterasi berhenti jika $L(\boldsymbol{\theta}^{(i+1)}; \mathbf{y}) \geq L(\boldsymbol{\theta}^{(i)}; \mathbf{y})$ sebesar nilai yang sangat rendah untuk serangkaian tahap iterasi.

2. Mengkaji dan mendapatkan penaksiran parameter spasial GOP melalui tahapan:

a. Untuk tiap hari dalam periode training, menghitung error model yang diperoleh dengan mengurangi nilai observasi terhadap prakiraan berdasarkan langkah 2a atau $\varepsilon_{s,t} = y_{s,t} - \hat{y}_{s,t}$ dimana $y_{s,t} = \beta_0 + \beta_1 x_{s,t} + \varepsilon_{s,t}$.

b. Untuk tiap hari dalam periode training dan untuk tiap himpunan pasangan lokasi pengamatan pada hari tersebut, menghitung jarak antar dua lokasi dengan jarak Euclidean $\|\mathbf{s}_i - \mathbf{s}_j\|$ dan menghitung setengah dari

$$\text{selisih kuadrat antar error } \frac{1}{2} [\varepsilon(\mathbf{s}_i) - \varepsilon(\mathbf{s}_j)]^2.$$

- c. Mengelompokkan jarak-jarak yang sudah diperoleh ke dalam *bin* B_l dengan titik tengah d_l , dimana l adalah suatu jarak.
- d. Menghitung nilai semivariogram empiris $\hat{\gamma}(d_l)$ pada jarak d_l dengan menghitung setengah dari ekspektasi kuadrat selisih antar error pada *bin* B_l , $\frac{1}{2} E[\varepsilon(s_i) - \varepsilon(s_j)]^2$, dimana lokasi s_i dan s_j adalah himpunan lokasi berbeda yang berada dalam *bin* B_l .
- e. Mengestimasi parameter semivariogram ρ^2, σ^2 dan r dari fungsi objektif yang diperoleh melalui kuadrat terkecil terboboti (*weighted least squares*) berdasarkan Cressie (1985) yang meminimumkan
$$g(\rho^2, \sigma^2, r) = \sum_{l=1}^N n_l \left(\frac{\hat{\gamma}(d_l) - [\rho^2 + \sigma^2 (1 - \exp(-d_l / r))]}{\rho^2 + \sigma^2 (1 - \exp(-d_l / r))} \right)^2,$$
dengan n_l adalah banyak pasangan lokasi yang berada pada *bin* B_l dan N adalah jumlah *bin* yang terbentuk.
- f. Karena ρ^2, σ^2 dan r tidak dapat diestimasi secara analitik, maka digunakan metode iteratif *Limited-Memory* BFGS (L-BFGS) untuk menyelesaikannya.

3.4 Kajian Aplikasi


Langkah-langkah analisis yang diperlukan untuk mencapai tujuan penelitian aplikatif pada Bab 1 adalah sebagai berikut :

3. Mengaplikasikan BMA dan GOP untuk mendapatkan prakiraan suhu udara terkalibrasi sesuai langkah-langkah berikut.
 - a. Melakukan standardisasi data, baik untuk data observasi maupun data parameter NWP. Teknik standardisasi yang diterapkan adalah mengurangi nilai tiap pengamatan dengan rata-rata, kemudian dibagi dengan akar variansnya (*scaled and centered*).
 - b. Mereduksi dimensi tiap parameter NWP dengan PCA berdasarkan matrik kovarian sehingga diperoleh skor-skor PC.

- c. Melakukan prakiraan suhu udara dengan observasi riil sebagai respon dan skor PC sebagai prediktor berdasarkan pemodelan dengan PLS, PCR, dan regresi Ridge.
- d. Membandingkan hasil prakiraan tiap anggota ensemble dan luaran NWP terhadap observasi secara deskriptif. Hal ini dilakukan untuk melihat dan mengevaluasi kebaikan ramalan kedua pendekatan sebelum diolah lebih lanjut dengan BMA dan GOP.
- e. Mengkalibrasi prakiraan ensemble untuk suhu udara harian menggunakan BMA berdasarkan *training window* 30 hari dengan tahapan:
 - 1) Meregresikan observasi riil terhadap prakiraan ensemble menggunakan *Maximum Likelihood* untuk mendapatkan koefisien bias regresi, yaitu $\beta_{0,m}$ dan $\beta_{1,m}$. Langkah ini dilakukan untuk setiap anggota ensemble m .
 - 2) Mengestimasi parameter bobot untuk tiap anggota ensemble w_m dan varians σ^2 dengan algoritma *Expectation-Maximization* dan menginterpretasikan parameter tersebut, khususnya bobot w_m .
 - 3) Menghitung mean, prakiraan BMA deterministik berdasarkan persamaan (2.26) untuk suatu hari tertentu.
 - 4) Membentuk kurva PDF BMA dan memperoleh estimasi interval BMA terkalibrasi di hari yang sama seperti pada langkah 3e, berdasarkan mean dan varians yang dihitung berdasarkan (2.26) dan (2.27).
 - 5) Menganalisis kebaikan prakiraan di hari tersebut berdasarkan RMSE dan membandingkannya dengan anggota ensemble.
 - 6) Membentuk *Verification Rank Histogram* (VRH) selama periode testing untuk melihat apakah prakiraan BMA sudah terkalibrasi atau masih bersifat *underdispersive* atau *overdispersive*.
- f. Memodelkan prakiraan NWP deterministik untuk suhu udara harian menggunakan GOP berdasarkan training 30 hari dengan tahapan:
 - 1) Menganalisis dan menguji signifikansi dependensi spasial suhu udara pada delapan stamet dengan Moran's I berdasarkan *cut-off distance* 30 km dan tingkat signifikansi α sebesar 0,05.

- 2) Meregresikan observasi riil terhadap prakiraan/luaran NWP menggunakan *Maximum Likelihood* untuk mendapatkan koefisien bias regresi anggota ensemble terpilih m , yaitu $\beta_{0,m}$ dan $\beta_{1,m}$.
 - 3) Menganalisis semivariogram empiris berdasarkan residual regresi.
 - 4) Mengestimasi parameter spasial pada variogram ρ^2, σ^2 dan r berdasarkan residual yang telah di-*binning* (dikelompokkan), dengan metode kuadrat terkecil terboboti dimana bobot yang digunakan adalah banyaknya observasi dalam tiap kelompok *binning*.
 - 5) Memperoleh prakiraan suhu udara untuk hari tertentu dan interval prediktif model GOP di hari tersebut dimana batas bawah dan batas atas diperoleh dari persentil ke-5 dan persentil ke-95.
 - 6) Mengevaluasi dan membandingkan akurasi prakiraan GOP dengan akurasi parameter NWP untuk suhu udara, yaitu t_{maxscr} untuk suhu maksimum dan t_{minscr} untuk suhu minimum.
- g. Untuk metode BMA, melakukan agregasi RMSE dan CRPS secara spasial, kemudian dirata-rata. Sementara untuk metode GOP, ketiga indikator kebaikan prakiraan sudah diperoleh sebelumnya dengan mempertimbangkan seluruh stamet yang diteliti.
- h. Mengevaluasi dan membandingkan kebaikan prakiraan BMA dan GOP menggunakan RMSE, *coverage* dan CRPS berdasarkan persamaan (2.40) dan (2.41).

Untuk mempermudah pemahaman, ilustrasi mengenai tahapan analisis untuk tujuan penelitian ketiga disajikan pada Gambar 3.3.



Gambar 3.3 Tahapan Analisis Data

Keterangan:

———— = Tahap penentuan variabel penelitian BMA

- - - - - = Tahap penentuan variabel penelitian GOP

(Halaman ini sengaja dikosongkan)

BAB IV

HASIL DAN PEMBAHASAN

Pada bab ini, agar dapat menjawab tujuan penelitian pada Bab 1, dibahas mengenai estimasi parameter *Bayesian Model Averaging* (BMA) menggunakan *Maximum Likelihood Estimation* untuk parameter β_m dan algoritma *Expectation-Maximization* untuk parameter bobot dan varians. Selain itu, dibahas pula tahapan singkat untuk mengestimasi parameter spasial model *Geostatistical Output Perturbation* (GOP) menggunakan fungsi objektif *Weighted Least Squares* yang diselesaikan secara iteratif dengan *Limited-Memory BFGS* (L-BFGS). Kemudian, kedua model tersebut digunakan untuk meramalkan suhu udara di 8 stasiun meteorologi (stamet) di Jabotabek.

4.1 Penaksiran Parameter BMA

Parameter BMA dapat diklasifikasikan ke dalam 2 bagian, yaitu parameter regresi β_m dan parameter bobot dan varians (w_m dan σ^2). Seluruh parameter tersebut berkontribusi terhadap koreksi bias yang dihitung dari tiap anggota ensemble dan digunakan untuk menghasilkan ramalan terkalibrasi beserta selang kepercayaan $(1-\alpha)100\%$ yang disesuaikan dengan distribusi dari data pengamatan. Berikut ini adalah penjabaran untuk memperoleh estimasi parameter-parameter tersebut.

4.1.1. Estimasi Parameter Regresi

Untuk tiap anggota ensemble m dimana $m=1,2,\dots,M$ dan $t=1,2,\dots,T$, dengan M dan T menyatakan banyaknya anggota ensemble dan jumlah hari/waktu dalam periode training, berlaku model pada persamaan (4.1):

$$y_t = \beta_{0,m} + \beta_{1,m}f_{mt} + \varepsilon_{mt} \quad (4.1)$$

dimana y_t adalah variabel respon (observasi suhu udara), f_{mt} adalah variabel prediktor (prakiraan suhu udara oleh anggota ensemble m), dan ε_{mt} adalah error regresi tiap anggota ensemble m , seluruhnya pada waktu ke- t . Untuk kasus suhu udara, respon y_t atau error ε_{mt} berdistribusi normal. Berdasarkan Rencher dan Schaalje (2008), beberapa asumsi yang seharusnya dipenuhi adalah:

- a. $E(\varepsilon_{mt}) = 0$ atau $E(y_t) = \beta_{0,m} + \beta_{1,m}f_{mt}$,

b. $\text{var}(\varepsilon_{mt}) = \sigma^2$ atau $\text{var}(y_t) = \sigma^2$,

c. $\text{cov}(\varepsilon_{mt}, \varepsilon_{mv}) = 0$ atau $\text{cov}(y_{mt}, y_{mv}) = 0$ untuk $t \neq v$.

Jadi, dapat dikatakan bahwa $y \sim N(\beta_{0,m} + \beta_{1,m}f_{mt}, \sigma^2)$ atau $\varepsilon \sim N(0, \sigma^2)$.

Setelah mengetahui distribusi dari respon atau error beserta karakteristik variabel yang diamati, maka langkah selanjutnya adalah memperoleh estimator parameter regresi untuk tiap anggota ensemble m , yaitu $\hat{\beta}_{0,m}$ dan $\hat{\beta}_{1,m}$, berdasarkan fungsi probabilitas berikut yang mengacu persamaan (2.1).

$$g(y) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2}(y_t - (\beta_{0,m} + \beta_{1,m}f_{mt}))^2\right)$$

Karakteristik dari $\hat{\beta}_{0,m}$ dan $\hat{\beta}_{1,m}$ adalah yang memaksimumkan likelihood $L(\beta_{0,m}, \beta_{1,m}, \sigma^2)$ dimana

$$\begin{aligned} L(\beta_{0,m}, \beta_{1,m}, \sigma^2) &= \prod_{t=1}^T \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2}(y_t - (\beta_{0,m} + \beta_{1,m}f_{mt}))^2\right) \\ &= (2\pi\sigma^2)^{-T/2} \exp\left(-\frac{1}{2\sigma^2} \sum_{t=1}^T (y_t - (\beta_{0,m} + \beta_{1,m}f_{mt}))^2\right) \end{aligned} \quad (4.2)$$

dengan fungsi ln-likelihood dari persamaan (4.2) adalah sebagai berikut.

$$\begin{aligned} l(\beta_{0,m}, \beta_{1,m}, \sigma^2) &= \ln L(\beta_{0,m}, \beta_{1,m}, \sigma^2) \\ &= -\frac{T}{2} \ln(2\pi) - \frac{T}{2} \ln(\sigma^2) - \frac{1}{2\sigma^2} \sum_{t=1}^T (y_t - (\beta_{0,m} + \beta_{1,m}f_{mt}))^2 \end{aligned} \quad (4.3)$$

Berdasarkan Rencher dan Schaalje (2008), estimator dari $\beta_{0,m}$ dan $\beta_{1,m}$, yaitu $\hat{\beta}_{0,m}$ dan $\hat{\beta}_{1,m}$, memaksimumkan persamaan (4.3).

$$\max_{\beta_{0,m}, \beta_{1,m}} l(\beta_{0,m}, \beta_{1,m}, \sigma^2)$$

Cara yang dilakukan untuk mendapatkan $\hat{\beta}_{0,m}$ dan $\hat{\beta}_{1,m}$ adalah menerapkan diferensial orde pertama dari persamaan (4.3) terhadap elemen β_m , lalu disamadengankan nol. Jika $Q = l(\beta_{0,m}, \beta_{1,m}, \sigma^2; y)$, maka $\hat{\beta}_{0,m}$ didapatkan melalui proses berikut.

$$\begin{aligned}
\frac{\partial Q}{\partial \beta_{0,m}} &= \frac{\partial}{\partial \beta_{0,m}} \left[-\frac{T}{2} \ln(2\pi) - \frac{T}{2} \ln(\sigma^2) - \frac{1}{2\sigma^2} \sum_{t=1}^T (y_t - (\beta_{0,m} + \beta_{1,m} f_{mt}))^2 \right] \\
&= 0 - 0 + \frac{1}{\sigma^2} \sum_{t=1}^T y_t - \beta_{0,m} - \beta_{1,m} f_{mt} = \frac{1}{\sigma^2} \left(\sum_{t=1}^T y_t - \sum_{t=1}^T \beta_{0,m} - \sum_{t=1}^T \beta_{1,m} f_{mt} \right) \\
&= \frac{1}{\sigma^2} \left(\sum_{t=1}^T y_t - T\beta_{0,m} - \beta_{1,m} \sum_{t=1}^T f_{mt} \right) = 0 \\
\sum_{t=1}^T y_t - T\hat{\beta}_{0,m} - \hat{\beta}_{1,m} \sum_{t=1}^T f_{mt} &= 0 \\
\hat{\beta}_{0,m} &= \frac{\sum_{t=1}^T y_t - \hat{\beta}_{1,m} \sum_{t=1}^T f_{mt}}{T} \tag{4.4}
\end{aligned}$$

Langkah yang serupa untuk mendapatkan $\hat{\beta}_{1,m}$ adalah

$$\begin{aligned}
\frac{\partial Q}{\partial \beta_{1,m}} &= \frac{\partial}{\partial \beta_{1,m}} \left[-\frac{T}{2} \ln(2\pi) - \frac{T}{2} \ln(\sigma^2) - \frac{1}{2\sigma^2} \sum_{t=1}^T (y_t - (\beta_{0,m} + \beta_{1,m} f_{mt}))^2 \right] \\
&= 0 - 0 + \frac{1}{\sigma^2} \sum_{t=1}^T f_{mt} (y_t - \beta_{0,m} - \beta_{1,m} f_{mt}) \\
&= \frac{1}{\sigma^2} \left(\sum_{t=1}^T f_{mt} y_t - \beta_{0,m} \sum_{t=1}^T f_{mt} - \beta_{1,m} \sum_{t=1}^T f_{mt}^2 \right) = 0 \\
\sum_{t=1}^T f_{mt} y_t - \hat{\beta}_{0,m} \sum_{t=1}^T f_{mt} - \hat{\beta}_{1,m} \sum_{t=1}^T f_{mt}^2 &= 0 \\
\hat{\beta}_{1,m} &= \frac{\sum_{t=1}^T f_{mt} y_t - \hat{\beta}_{0,m} \sum_{t=1}^T f_{mt}}{\sum_{t=1}^T f_{mt}^2} . \tag{4.5}
\end{aligned}$$

Karena $\hat{\beta}_{0,m}$ dan $\hat{\beta}_{1,m}$ pada persamaan (4.4) dan (4.5) masih mengandung kedua parameter yang juga ingin diestimasi, maka dengan mensubstitusikan $\hat{\beta}_{0,m}$ ke dalam persamaan (4.5) diperoleh hasil berikut.

$$\hat{\beta}_{1,m} = \frac{\sum_{t=1}^T f_{mt} y_t - \left(\frac{\sum_{t=1}^T y_t - \hat{\beta}_{1,m} \sum_{t=1}^T f_{mt}}{T} \right) \sum_{t=1}^T f_{mt}}{\sum_{t=1}^T f_{mt}^2}$$

$$T\hat{\beta}_{1,m} \sum_{t=1}^T f_{mt}^2 = T \sum_{t=1}^T f_{mt} y_t - \left(\sum_{t=1}^T f_{mt} \right) \left(\sum_{t=1}^T y_t \right) + \hat{\beta}_{1,m} \left(\sum_{t=1}^T f_{mt} \right)^2$$

$$T\hat{\beta}_{1,m} \sum_{t=1}^T f_{mt}^2 - \hat{\beta}_{1,m} \left(\sum_{t=1}^T f_{mt} \right)^2 = T \sum_{t=1}^T f_{mt} y_t - \left(\sum_{t=1}^T f_{mt} \right) \left(\sum_{t=1}^T y_t \right)$$

Dengan demikian, $\hat{\beta}_{1,m}$ dapat diestimasi menggunakan persamaan (4.6).

$$\hat{\beta}_{1,m} = \frac{T \sum_{t=1}^T f_{mt} y_t - \left(\sum_{t=1}^T f_{mt} \right) \left(\sum_{t=1}^T y_t \right)}{T \sum_{t=1}^T f_{mt}^2 - \left(\sum_{t=1}^T f_{mt} \right)^2} = \frac{\sum_{t=1}^T (f_{mt} - \bar{f}_m)(y_t - \bar{y})}{\sum_{t=1}^T (f_{mt} - \bar{f}_m)^2} \quad (4.6)$$

Selanjutnya, $\hat{\beta}_{1,m}$ dari persamaan (4.6) disubstitusikan ke persamaan (4.7).

$$\hat{\beta}_{0,m} = \bar{y} - \hat{\beta}_{1,m} \bar{f}_m \quad (4.7)$$

Persamaan (4.6) dan (4.7) adalah serupa dengan hasil estimasi koefisien regresi yang terdapat dalam Rencher dan Schaalje (2008).

4.1.2. Estimasi Parameter Bobot dan Varians

Algoritma EM digunakan untuk mengestimasi parameter yang tidak dapat diestimasi dengan MLE dengan menerapkan konsep likelihood *complete-data* $L(\boldsymbol{\theta}; \mathbf{y}, \mathbf{z})$ berdasarkan likelihood *incomplete-data* $L(\boldsymbol{\theta}; \mathbf{y})$ yang tidak memiliki penyelesaian secara analitik (McLachlan dan Khrisnan, 2008). Berikut ini merupakan tahapan algoritma EM dalam mengestimasi bobot w_m untuk anggota ensemble m dan varians σ^2 pada kasus respon atau error berdistribusi normal.

1. Mendapatkan likelihood *incomplete-data*

Berdasarkan McLachlan dan Khrisnan (2008), likelihood *incomplete-data* dibentuk untuk meyakinkan dan memastikan bahwa parameter yang ingin diestimasi tidak memiliki solusi secara analitik. Untuk kasus ini, berlaku bahwa

$$\boldsymbol{\theta} = (w_1 \ w_2 \ \dots \ w_m \ \sigma^2)' = (\mathbf{w}' \ \sigma^2)'; \mathbf{y} = (y_1, y_2, \dots, y_T)'; \mathbf{f}_m = (f_{m1}, f_{m2}, \dots, f_{mT})'$$

dimana $w_m \geq 0$ dan $\sum_{m=1}^M w_m = 1$ dengan \mathbf{y} dan \mathbf{f}_m adalah vektor yang berukuran $T \times 1$,

T merupakan panjang periode *training*. Dengan fungsi padat probabilitas (PDF) prediktif BMA mengacu pada persamaan (2.24), dapat dibentuk likelihood

$$L(\boldsymbol{\theta}; \mathbf{y}) = \prod_{t=1}^T g(y_t; \boldsymbol{\theta}) = \prod_{t=1}^T \left(\sum_{m=1}^M w_m g_m(y_t | f_{mt}) \right) \quad (4.8)$$

dimana f_{mt} merupakan prakiraan tiap anggota ensemble m pada hari ke- t . Fungsi ln-likelihood dari persamaan (4.8) ditunjukkan pada persamaan (4.9).

$$l(\boldsymbol{\theta}; \mathbf{y}) = \ln L(\boldsymbol{\theta}; \mathbf{y}) = \sum_{t=1}^T \ln \left(\sum_{m=1}^M w_m g_m(y_t | f_{mt}) \right) \quad (4.9)$$

Estimasi untuk bobot w_m sebagai bagian dari parameter $\boldsymbol{\theta}$ diperoleh dari derivatif

pertama dengan cara $\frac{\partial l(\boldsymbol{\theta}; \mathbf{y})}{\partial \boldsymbol{\theta}} \simeq \frac{\partial l(\boldsymbol{\theta}; \mathbf{y})}{\partial w_m} = 0$.

Karena $w_M = 1 - w_1 - w_2 - \dots - w_{M-1} = 1 - \sum_{m=1}^{M-1} w_m$, maka w_M dapat dicari

setelah estimasi untuk w_1, w_2, \dots, w_{M-1} diperoleh dengan syarat $\sum_{m=1}^M w_m = 1$

(McLachlan dan Krishnan, 2008). Dengan demikian, untuk w_j dimana $j = 1, 2, \dots, M-1$, maka derivatif pertama untuk mendapatkan \hat{w}_j adalah sebagai berikut.

$$\begin{aligned} \frac{\partial l(\boldsymbol{\theta}; \mathbf{y})}{\partial w_j} &= \frac{\partial}{\partial w_j} \left[\sum_{t=1}^T \ln \left(\sum_{j=1}^{M-1} w_j g_j(y_t | f_{jt}) + w_M g_M(y_t | f_{Mt}) \right) \right] \\ &= \sum_{t=1}^T \left[\frac{g_j(y_t | f_{jt})}{\sum_{j=1}^{M-1} w_j g_j(y_t | f_{jt}) + w_M g_M(y_t | f_{Mt})} - \frac{g_M(y_t | f_{Mt})}{\sum_{j=1}^{M-1} w_j g_j(y_t | f_{jt}) + w_M g_M(y_t | f_{Mt})} \right] \\ &= \sum_{t=1}^T \left[\frac{g_j(y_t | f_{jt}) - g_M(y_t | f_{Mt})}{\sum_{m=1}^M w_m g_m(y_t | f_{mt})} \right] \end{aligned}$$

Jika $\frac{\partial l(\boldsymbol{\theta}; \mathbf{y})}{\partial w_j}$ disamadengankan nol untuk mendapatkan \hat{w}_j , maka

$$\sum_{t=1}^T \left[\frac{g_j(y_t | f_{jt}) - g_M(y_t | f_{Mt})}{\sum_{m=1}^M w_m g_m(y_t | f_{mt})} \right] = 0. \quad (4.10)$$

Berdasarkan persamaan (4.10), solusi untuk \hat{w}_j rumit untuk dicari sebab w_j berada pada posisi penyebut sehingga tidak memungkinkan bagi \hat{w}_j diperoleh secara analitik. Untuk menemukan penyelesaian \hat{w}_j , diperlukan pendekatan iteratif, dalam hal ini algoritma EM yang dikembangkan oleh Dempster, Laird, dan Rubin (1977). Kendati σ^2 dapat diestimasi secara analitis, namun Vrugt, Diks, dan Clark (2008) menyarankan penggunaan EM untuk menemukan $\hat{\sigma}^2$, alih-alih menggunakan MLE biasa.

Untuk algoritma EM, McLachlan dan Krishnan (2008) merekomendasikan penggunaan variabel laten yang tidak dapat diamati (*unobservable*), dinotasikan dengan \mathbf{Z} , yaitu $\mathbf{Z} = (\mathbf{Z}_1^T \mathbf{Z}_2^T \dots \mathbf{Z}_T^T)$, dengan *superscript T* menyatakan transpos sementara *subscript T* menyatakan periode *training* ke- T dimana $t = 1, 2, \dots, T$. Berlaku pula bahwa $\mathbf{Z}_t = (z_{1t} \ z_{2t} \ \dots \ z_{Mt})$. Dalam suatu waktu/hari ke- t , hanya salah satu elemen \mathbf{Z}_t saja yang bernilai 1, sementara elemen lainnya bernilai 0. Jika kondisi tersebut dinotasikan dalam fungsi indikator dimana $m = 1, 2, \dots, M$,

$$\mathbf{I}_{(z_{mt}=k)} = \begin{cases} 1, & z_{mt} = k \\ 0, & z_{mt} \neq k \end{cases}$$

dengan k merupakan representasi prakiraan anggota ensemble yang “terbaik”.

Karena tiap anggota ensemble m berdistribusi normal dengan $\mu_{mt} = \beta_{0,m} + \beta_{1,m}f_{mt}$, maka dapat dikatakan bahwa

$$\begin{aligned} y_t | (z_{mt} = 1) &\sim N(\beta_{0,1} + \beta_{1,1}f_{1t}, \sigma^2) \\ y_t | (z_{mt} = 2) &\sim N(\beta_{0,2} + \beta_{1,2}f_{2t}, \sigma^2) \\ &\vdots \\ y_t | (z_{mt} = M) &\sim N(\beta_{0,M} + \beta_{1,M}f_{Mt}, \sigma^2) \end{aligned}$$

dengan bobot w berikut adalah representasi dari probabilitas variabel laten \mathbf{Z} pada waktu ke- t , yaitu $p(z_{mt} = 1) = w_1, p(z_{mt} = 2) = w_2, \dots, p(z_{mt} = M) = w_M = 1 - \sum_{m=1}^{M-1} w_m$.

Bobot untuk tiap anggota ensemble di tiap waktu akan selalu berubah yang mana hal ini merefleksikan bahwa kebaikan ramalan tiap anggota ensemble selama *windowing* berkontribusi besar dalam penentuan nilai bobot (Raftery *et al.*, 2005).

2. Mendapatkan likelihood *complete-data*

Tahap ini dilakukan untuk mendapatkan likelihood *complete-data* yang digunakan pada tahap EM berikutnya. Berdasarkan McLachlan dan Krishnan (2008), likelihood ini didapatkan dengan memasukkan peran dari variabel laten \mathbf{Z} . Dengan menggunakan fungsi indikator $\mathbf{I}_{(z_{mt}=k)}$ untuk merepresentasikan variabel laten, maka fungsi likelihood *complete-data* adalah

$$L(\boldsymbol{\theta}; \mathbf{y}, \mathbf{z}) = \prod_{t=1}^T \sum_{m=1}^M \mathbf{I}_{(z_{mt}=k)} w_m g_m(y_t | f_{mt})$$

atau

$$\begin{aligned} L(\boldsymbol{\theta}; \mathbf{y}, \mathbf{z}) &= \exp \left(\sum_{t=1}^T \sum_{m=1}^M \mathbf{I}_{(z_{mt}=k)} \left[\ln w_m + \ln g_m(y_t | f_{mt}) \right] \right) \\ &= \exp \left(\sum_{t=1}^T \sum_{m=1}^M \mathbf{I}_{(z_{mt}=k)} \left[\ln w_m - \frac{1}{2} \ln \sigma^2 - \frac{1}{2} \ln 2\pi - \frac{1}{2\sigma^2} (y_t - f_{mt})^2 \right] \right). \end{aligned}$$

3. Melakukan tahap *Expectation*

Tahap *Expectation* atau sering dituliskan E dilakukan secara iteratif untuk mendapatkan ekspektasi dari fungsi likelihood atau ln-likelihood *complete-data* (Lange, 2010). Berdasarkan McLachlan dan Krishnan (2008), jika i menyatakan iterasi ke- i , maka

$$\begin{aligned} Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)}) &= E_{\boldsymbol{\theta}^{(i)}} [\ln L(\boldsymbol{\theta}; \mathbf{y}, \mathbf{z})] \\ &= E_{\boldsymbol{\theta}^{(i)}} \left[\sum_{t=1}^T \sum_{m=1}^M \mathbf{I}_{(z_{mt}=k)} \left(\ln w_m - \frac{1}{2} \ln \sigma^2 - \frac{1}{2} \ln 2\pi - \frac{1}{2\sigma^2} (y_t - f_{mt})^2 \right) \right]. \end{aligned}$$

Dengan demikian,

$$Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)}) = \left[\sum_{t=1}^T \sum_{m=1}^M E_{\boldsymbol{\theta}^{(i)}} \mathbf{I}_{(z_{mt}=k)} \left(\ln w_m - \frac{1}{2} \ln \sigma^2 - \frac{1}{2} \ln 2\pi - \frac{1}{2\sigma^2} (y_t - f_{mt})^2 \right) \right]. \quad (4.11)$$

Dari persamaan (4.11), dapat dikatakan bahwa untuk suatu periode/hari ke- t , hanya ada satu elemen \mathbf{Z}_t yang bernilai 1 atau salah satu anggota ensemble m dimana $z_{mt} = 1$. Jika dijabarkan, maka diperoleh

$$\begin{aligned} E_{\boldsymbol{\theta}^{(i)}} \mathbf{I}_{(z_{mt}=k)} &= E_{\boldsymbol{\theta}^{(i)}} (z_{mt} | y) = \Pr_{\boldsymbol{\theta}^{(i)}} (z_{mt} = 1 | y) \\ &= z_{mt}^{(i)} \end{aligned}$$

dengan

$$z_{mt}^{(i)} = \frac{w_m g_m(y_t | f_{mt}, \sigma^{(i-1)})}{\sum_{l=1}^M w_l g_l(y_t | f_{lt}, \sigma^{(i-1)})}. \quad (4.12)$$

Persamaan (4.12) adalah probabilitas posterior dari observasi pada waktu ke- t untuk anggota ensemble m (McLachlan dan Krishnan, 2008). Jadi,

$$Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)}) = \left[\sum_{t=1}^T \sum_m^M z_{mt}^{(i)} \left(\ln w_m - \frac{1}{2} \ln \sigma^2 - \frac{1}{2} \ln 2\pi - \frac{1}{2\sigma^2} (y_t - f_{mt})^2 \right) \right].$$

4. Melakukan Tahap *Maximization*

Langkah terakhir dari algoritma EM, seperti yang terdapat dalam McLachlan dan Krishnan (2008), adalah memilih $\boldsymbol{\theta}^{(i+1)}$ yang memaksimumkan $Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)})$ dimana

$$Q(\boldsymbol{\theta}^{(i+1)} | \boldsymbol{\theta}^{(i)}) \geq Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)})$$

dengan kendala $w_1 + w_2 + \dots + w_M = 1$ dan $\boldsymbol{\theta} = (\mathbf{w}', \sigma^2)'$. Serupa dengan tahap *Expectation*, tahap *Maximization* atau M juga dilakukan secara iteratif. Berdasarkan Lange (2010), estimasi untuk $\boldsymbol{\theta}^{(i+1)}$ yang memaksimumkan

$$Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)}) \text{ dapat diperoleh dengan } \frac{\partial Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)})}{\partial \boldsymbol{\theta}} = \mathbf{0}.$$

a. Estimasi w_m pada iterasi ke- i $w_m^{(i)}$

Berdasarkan karakteristik observasi laten \mathbf{Z}_t dimana $z_{1t} + z_{2t} + \dots + z_{Mt} = 1$ untuk satu hari t , maka hal ini mengakibatkan

$$\sum_{t=1}^T z_{1t} + \sum_{t=1}^T z_{2t} + \dots + \sum_{t=1}^T z_{Mt} = \sum_{t=1}^T (z_{1t} + z_{2t} + \dots + z_{Mt}) = T.$$

Estimasi untuk \mathbf{w} dapat dicari melalui $\frac{\partial Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)})}{\partial \mathbf{w}} = \mathbf{0}$ dengan

$$Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)}) = \left[\sum_{t=1}^T z_{1t}^{(i)} \right] \ln w_1 + \left[\sum_{t=1}^T z_{2t}^{(i)} \right] \ln w_2 + \dots + \left[\sum_{t=1}^T z_{Mt}^{(i)} \right] \ln w_M + C$$

$$\text{dimana } C = \sum_{t=1}^T \sum_m^M z_{mt}^{(i)} \left(-\frac{1}{2} \ln \sigma^2 - \frac{1}{2} \ln 2\pi - \frac{1}{2\sigma^2} (y_t - f_{mt})^2 \right).$$

Jika dimisalkan $M = 2$, maka $w_1 + w_2 = 1$ dengan $w_2 = 1 - w_1$, sehingga diperoleh persamaan (4.13).

$$\begin{aligned} \frac{\partial Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)})}{\partial w_1} &= \frac{\partial}{\partial w_1} \left(\left[\sum_{t=1}^T z_{1t}^{(i)} \right] \ln w_1 + \left[\sum_{t=1}^T z_{2t}^{(i)} \right] \ln w_2 + C \right) \\ &= \frac{\partial}{\partial w_1} \left(\left[\sum_{t=1}^T z_{1t}^{(i)} \right] \ln w_1 + \left[\sum_{t=1}^T z_{2t}^{(i)} \right] \ln (1 - w_1) + C \right) \\ &= \frac{\sum_{t=1}^T z_{1t}^{(i)}}{w_1} - \frac{\sum_{t=1}^T z_{2t}^{(i)}}{1 - w_1} \end{aligned} \quad (4.13)$$

Setelah persamaan (4.13) disamadengankan nol, yaitu $\frac{\partial Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)})}{\partial w_1} = 0$, diperoleh

$$w_1^{(i)} \left(1 + \frac{\sum_{t=1}^T z_{1t}^{(i)}}{\sum_{t=1}^T z_{2t}^{(i)}} \right) = \frac{\sum_{t=1}^T z_{1t}^{(i)}}{\sum_{t=1}^T z_{2t}^{(i)}} \rightarrow w_1^{(i)} = \frac{\sum_{t=1}^T z_{1t}^{(i)}}{\sum_{t=1}^T z_{1t}^{(i)} + \sum_{t=1}^T z_{2t}^{(i)}} = \frac{1}{T} \sum_{t=1}^T z_{1t}^{(i)}$$

$$\text{sehingga } w_2^{(i)} = 1 - w_1^{(i)} = 1 - \frac{1}{T} \sum_{t=1}^T z_{1t}^{(i)} = \frac{\sum_{t=1}^T z_{1t}^{(i)} + \sum_{t=1}^T z_{2t}^{(i)} - \sum_{t=1}^T z_{1t}^{(i)}}{T} = \frac{1}{T} \sum_{t=1}^T z_{2t}^{(i)}.$$

Secara umum, untuk ensemble berukuran M , berlaku bahwa

$$w_m^{(i)} = \frac{1}{T} \sum_{t=1}^T z_{mt}^{(i)}, m = 1, 2, \dots, M. \quad (4.14)$$

b. Estimasi varians pada iterasi ke- i $\sigma^{2(i)}$

Dengan langkah serupa seperti sebelumnya, estimasi $\sigma^{2(i)}$ didapatkan

dengan memaksimumkan $Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)})$ berdasarkan $\frac{\partial Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)})}{\partial \sigma^2} = 0$. Berlaku bahwa

$$Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)}) = -\frac{1}{2} \sum_{t=1}^T \sum_{m=1}^M z_{mt}^{(i)} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{t=1}^T \sum_{m=1}^M z_{mt}^{(i)} (y_t - f_{mt})^2 + D$$

$$\text{dengan } D = \sum_{t=1}^T \sum_{m=1}^M z_{mt}^{(i)} \left(\ln w_m - \frac{1}{2} \ln 2\pi \right).$$

Derivatif $Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)})$ terhadap σ^2 adalah sebagai berikut.

$$\begin{aligned} \frac{\partial Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)})}{\partial \sigma^2} &= \frac{\partial}{\partial \sigma^2} \left(-\frac{1}{2} \sum_{t=1}^T \sum_{m=1}^M z_{mt}^{(i)} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{t=1}^T \sum_{m=1}^M z_{mt}^{(i)} (y_t - f_{mt})^2 + D \right) \\ &= -\frac{1}{2\sigma^2} \sum_{t=1}^T \sum_{m=1}^M z_{mt}^{(i)} + \frac{1}{2(\sigma^2)^2} \sum_{t=1}^T \sum_{m=1}^M z_{mt}^{(i)} (y_t - f_{mt})^2 + 0 \end{aligned} \quad (4.15)$$

Hasil dari persamaan (4.15) kemudian disamadengankan nol menjadi

$$\begin{aligned} \frac{\partial Q(\boldsymbol{\theta} | \boldsymbol{\theta}^{(i)})}{\partial \sigma^2} &= 0 \\ \frac{1}{2\sigma^{2(i)}} \sum_{t=1}^T \sum_{m=1}^M z_{mt}^{(i)} &= \frac{1}{2(\sigma^{2(i)})^2} \sum_{t=1}^T \sum_{m=1}^M z_{mt}^{(i)} (y_t - f_{mt})^2 \\ \frac{1}{2\sigma^{2(i)}} \left(\sum_{t=1}^T z_{1t}^{(i)} + \dots + \sum_{t=1}^T z_{Mt}^{(i)} \right) &= \frac{1}{2(\sigma^{2(i)})^2} \sum_{t=1}^T \sum_{m=1}^M z_{mt}^{(i)} (y_t - f_{mt})^2 \\ \sigma^{2(i)} T &= \sum_{t=1}^T \sum_{m=1}^M z_{mt}^{(i)} (y_t - f_{mt})^2 \\ \sigma^{2(i)} &= \frac{\sum_{t=1}^T \sum_{m=1}^M z_{mt}^{(i)} (y_t - f_{mt})^2}{T} . \end{aligned} \quad (4.16)$$

Persamaan (4.14) dan (4.16) untuk mengestimasi bobot w_m dan varians σ^2 adalah serupa dengan hasil estimasi yang terdapat dalam Vrugt *et al.* (2008).

Konvergensi Iterasi:

Tahap E dan M terus dilakukan secara iteratif hingga konvergen. Untuk $i=0,1,2,\dots$, konvergensi terjadi saat $\boldsymbol{\theta}^{(i+1)} - \boldsymbol{\theta}^{(i)}$ sebesar batas toleransi yang sangat rendah, misal 10^{-4} atau 10^{-6} . Ekuivalen dengan syarat konvergensi sebelumnya, McLachlan dan Krishnan (2008) menyatakan bahwa konvergensi tercapai jika likelihood *incomplete-data* tidak menurun setelah iterasi ke-($i+1$), yaitu $L(\boldsymbol{\theta}^{(i+1)}; \mathbf{y}) \geq L(\boldsymbol{\theta}^{(i)}; \mathbf{y})$, setelah serangkaian proses iterasi.

4.2 Penaksiran Parameter GOP

Selain parameter β_0 dan β_1 , GOP juga memiliki parameter spasial *nugget* ρ^2 , *partial sill* σ^2 dan *range* r yang digunakan untuk memodifikasi hasil ramalan regresi linier sederhana berdasarkan residual model regresi sehingga memenuhi persamaan (2.35). Model GOP oleh Gel *et al.* (2004) mengadopsi konsep yang serupa dengan Cressie (1993) dalam mendapatkan estimasi parameter variogram. Tujuannya adalah memperoleh estimasi ρ^2 , σ^2 dan r yang meminimumkan persamaan (4.17) yang diperoleh dari metode kuadrat terkecil terboboti.

$$g(\rho^2, \sigma^2, r) = \sum_{l=1}^k n_l \left(\frac{\hat{\gamma}(d_l)}{\rho^2 + \sigma^2(1 - e^{-d_l/r})} - 1 \right)^2, \rho^2, \sigma^2, r \geq 0 \quad (4.17)$$

Sebelum mengestimasi ρ^2 , σ^2 dan r , langkah pertama yang dilakukan adalah menghitung $\hat{\gamma}(d_l)$ dengan tahapan sebagai berikut (Berrocal *et al.*, 2007).

- Untuk tiap hari dalam periode training, menghitung error model yang diperoleh dengan mengurangi nilai observasi terhadap prakiraan berdasarkan langkah 2a atau $\varepsilon_{s,t} = y_{s,t} - \hat{y}_{s,t}$.
- Untuk tiap hari dalam periode training dan untuk tiap pasangan lokasi pengamatan pada hari tersebut, menghitung jarak antar lokasi $d(i,j)$ dengan jarak Euclidean $\|\mathbf{s}_i - \mathbf{s}_j\| = \sqrt{(\mathbf{u}_i - \mathbf{u}_j)^2 + (\mathbf{v}_i - \mathbf{v}_j)^2}$ dimana u dan v merupakan koordinat lintang dan bujur stasiun meteorologi s dan menghitung setengah dari selisih kuadrat antar error $\frac{1}{2}[\varepsilon(\mathbf{s}_i) - \varepsilon(\mathbf{s}_j)]^2$.
- Mengelompokkan jarak-jarak yang ada ke dalam *bin* B_l dengan titik tengah (*midpoint*) d_l , dimana l adalah suatu jarak, hingga diperoleh k atau banyaknya pasangan jarak antar lokasi yang berada pada bin B_l .
- Menghitung nilai semivariogram empiris $\hat{\gamma}(d_l)$ pada jarak d_l dengan menghitung setengah dari ekspektasi kuadrat selisih antar error pada bin B_l ,

$$\hat{\gamma}(d_l) = \frac{1}{2k} \sum_{i=1}^k \left(\varepsilon(\mathbf{s}_{i+d_l}) - \varepsilon(\mathbf{s}_i) \right)^2 \text{ dimana } d_l = d_l(1), d_l(2), \dots$$

Setelah memperoleh $\hat{\gamma}(d_l)$ pada tiap jarak d_l , langkah berikutnya adalah mendapatkan $\hat{\rho}^2, \hat{\sigma}^2$ dan \hat{r} . Untuk mendapatkan estimasi ketiga parameter tersebut secara analitik, persamaan (4.17) didiferensialkan satu kali terhadap masing-masing parameter, kemudian disamadengankan nol.

1. *Nugget* ρ^2

$$\begin{aligned}
\frac{\partial g(\rho^2, \sigma^2, r)}{\partial \rho^2} &= \frac{\partial}{\partial \rho^2} \left(\sum_{l=1}^k n_l \left(\frac{\hat{\gamma}(d_l)}{\rho^2 + \sigma^2(1 - e^{-d_l/r})} - 1 \right)^2 \right) \\
&= \sum_{l=1}^k n_l \frac{\partial}{\partial \rho^2} \left(\hat{\gamma}(d_l) \left[\rho^2 + \sigma^2(1 - e^{-d_l/r}) \right]^{-1} - 1 \right)^2 \\
&= \sum_{l=1}^k n_l 2 \left(\hat{\gamma}(d_l) \left[\rho^2 + \sigma^2(1 - e^{-d_l/r}) \right]^{-1} - 1 \right) \times \\
&\quad \left(-\hat{\gamma}(d_l) \left[\rho^2 + \sigma^2(1 - e^{-d_l/r}) \right]^{-2} \right) \\
&= -2 \sum_{l=1}^k n_l \frac{\hat{\gamma}(d_l)}{[\rho^2 + \sigma^2(1 - e^{-d_l/r})]^2} \left(\frac{\hat{\gamma}(d_l)}{\rho^2 + \sigma^2(1 - e^{-d_l/r})} - 1 \right)
\end{aligned} \tag{4.18}$$

Persamaan (4.18) mengindikasikan bahwa $\frac{\partial g(\rho^2, \sigma^2, r)}{\partial \rho^2} = 0$ akan memberikan

hasil yang tidak *close-form* sebab $\hat{\rho}^2$ turut mengandung $\hat{\sigma}^2$ dan \hat{r} .

2. *Partial sill* σ^2

$$\begin{aligned}
\frac{\partial g(\rho^2, \sigma^2, r)}{\partial \sigma^2} &= \frac{\partial}{\partial \sigma^2} \left(\sum_{l=1}^k n_l \left(\frac{\hat{\gamma}(d_l)}{\rho^2 + \sigma^2(1 - e^{-d_l/r})} - 1 \right)^2 \right) \\
&= \sum_{l=1}^k n_l \frac{\partial}{\partial \sigma^2} \left(\hat{\gamma}(d_l) \left[\rho^2 + \sigma^2(1 - e^{-d_l/r}) \right]^{-1} - 1 \right)^2 \\
&= \sum_{l=1}^k n_l 2 \left(\hat{\gamma}(d_l) \left[\rho^2 + \sigma^2(1 - e^{-d_l/r}) \right]^{-1} - 1 \right) \times \\
&\quad \left(-\hat{\gamma}(d_l) (1 - e^{-d_l/r}) \left[\rho^2 + \sigma^2(1 - e^{-d_l/r}) \right]^{-2} \right) \\
&= -2 \sum_{l=1}^k n_l \frac{\hat{\gamma}(d_l) (1 - e^{-d_l/r})}{[\rho^2 + \sigma^2(1 - e^{-d_l/r})]^2} \left(\frac{\hat{\gamma}(d_l)}{\rho^2 + \sigma^2(1 - e^{-d_l/r})} - 1 \right)
\end{aligned} \tag{4.19}$$

Sama halnya dengan persamaan (4.18), persamaan (4.19) mengindikasikan bahwa

$$\frac{\partial g(\rho^2, \sigma^2, r)}{\partial \sigma^2} = 0 \text{ akan memberikan hasil yang tidak } close\text{-form sebab } \hat{\sigma}^2 \text{ turut}$$

mengandung $\hat{\rho}^2$ dan \hat{r} .

3. Range r

$$\begin{aligned} \frac{\partial g(\rho^2, \sigma^2, r)}{\partial r} &= \frac{\partial}{\partial r} \left(\sum_{l=1}^k n_l \left(\frac{\hat{\gamma}(d_l)}{\rho^2 + \sigma^2 (1 - e^{-d_l/r})} - 1 \right)^2 \right) \\ &= \sum_{l=1}^k n_l \frac{\partial}{\partial r} \left(\frac{\hat{\gamma}(d_l)}{\rho^2 + \sigma^2 (1 - e^{-d_l/r})} - 1 \right)^2 \\ &= \sum_{l=1}^k n_l \frac{\partial}{\partial r} \left(\hat{\gamma}(d_l) \left[\rho^2 + \sigma^2 (1 - e^{-d_l/r}) \right]^{-1} - 1 \right)^2 \\ &= \sum_{l=1}^k 2n_l \left(-\hat{\gamma}(d_l) \sigma^2 \left[\rho^2 + \sigma^2 (1 - e^{-d_l/r}) \right]^{-2} \right) \times \\ &\quad \left(\hat{\gamma}(d_l) \left[\rho^2 + \sigma^2 (1 - e^{-d_l/r}) \right]^{-1} - 1 \right) \left(-d_l r^{-2} e^{-d_l/r} \right) \\ &= 2 \frac{\sigma^2}{r^2} \sum_{l=1}^k n_l d_l e^{-d_l/r} \frac{\hat{\gamma}(d_l)}{[\rho^2 + \sigma^2 (1 - e^{-d_l/r})]^2} \left(\frac{\hat{\gamma}(d_l)}{\rho^2 + \sigma^2 (1 - e^{-d_l/r})} - 1 \right) \end{aligned} \quad (4.20)$$

Diindikasikan bahwa $\frac{\partial g(\rho^2, \sigma^2, r)}{\partial r} = 0$ pada persamaan (4.20) akan memberikan

hasil yang tidak *close-form* sebab \hat{r} turut mengandung $\hat{\rho}^2$ dan $\hat{\sigma}^2$.

Jadi, diperlukan pendekatan iteratif untuk memperoleh estimasi ketiga parameter tersebut, diantaranya dengan *Limited-Memory* BFGS (L-BFGS) (Berrocal *et al.*, 2007). Algoritma L-BFGS merupakan pendekatan yang digunakan pada kasus fungsi objektif non-linier berkendala maupun tidak berkendala dengan parameter yang cukup banyak, seperti persamaan (4.17).

Berdasarkan Liu dan Nocedal (1989), berlaku vektor gradien jika $\mathbf{z} = [\rho^2 \ \sigma^2 \ r]^T$,

$$\nabla g(\mathbf{z}) = \left[\frac{\partial g(\rho^2, \sigma^2, r)}{\partial \rho^2} \quad \frac{\partial g(\rho^2, \sigma^2, r)}{\partial \sigma^2} \quad \frac{\partial g(\rho^2, \sigma^2, r)}{\partial r} \right]^T \quad (4.21)$$

dengan tahapan estimasi berikut dimana $k = 0, 1, 2, \dots$

1. Menentukan nilai awal untuk \mathbf{z} dan \mathbf{H} , yaitu \mathbf{z}_0 dan \mathbf{H}_0 . Pada iterasi $k = 0$, \mathbf{z}_0 bernilai non-negatif sesuai dengan kendala yang wajib dipenuhi seperti pada Cressie (1993), yaitu $\rho^2, \sigma^2, r \geq 0$, dan \mathbf{H}_0 adalah matrik simetris definit positif, misalnya matrik identitas atau \mathbf{I} . Selain itu, menentukan m atau suatu bilangan integer yang positif untuk menentukan seberapa panjang informasi \mathbf{H}_0 digunakan dalam memperbarui iterasi. Lalu, menetapkan nilai β dan γ dimana

$$\begin{aligned} 0 < \gamma < 0.5 \\ \gamma < \beta < 1 \end{aligned}$$

Umumnya, m tidak lebih daripada 10 agar iterasi berjalan cukup singkat. Karena L-BFGS didasari konsep gradien konjugat, maka γ disarankan sangat rendah, misal 10^{-4} , dan β jauh lebih besar, misal 0,1.

2. Menghitung $\Delta \mathbf{z}_k = -\mathbf{H}_k \nabla g(\mathbf{z}_k)$ dan $\mathbf{z}_{k+1} = \mathbf{z}_k + \alpha_k \Delta \mathbf{z}_k$ dimana $\nabla g(\mathbf{z}_k)$ adalah gradien fungsi pada titik \mathbf{z}_k dan konstanta α_k memenuhi syarat Wolfe:

- a. $g(\mathbf{z}_k + \alpha_k \Delta \mathbf{z}_k) \leq g(\mathbf{z}_k) + \gamma \alpha_k [\nabla g(\mathbf{z}_k)]^T \Delta \mathbf{z}_k$
- b. $[\nabla g(\mathbf{z}_k + \alpha_k \Delta \mathbf{z}_k)]^T \Delta \mathbf{z}_k \geq \beta [\nabla g(\mathbf{z}_k)]^T \Delta \mathbf{z}_k$

Untuk $k = 0$, umumnya α_0 bernilai 1.

3. Jika $\|\nabla g(\mathbf{z}_{k+1}) - \nabla g(\mathbf{z}_k)\| < \varepsilon$, dimana ε merupakan bilangan yang sangat kecil, maka iterasi dihentikan. Jika tidak, iterasi dilanjutkan ke langkah 4.
4. Memperbarui \mathbf{H}_k berdasarkan informasi \mathbf{H}_0 sebanyak \hat{m} kali sehingga diperoleh \mathbf{H}_{k+1} dengan $\hat{m} = \min(k+1, m)$. Makin tinggi konstanta m , maka \mathbf{H}_0 makin konsisten digunakan untuk memperbarui \mathbf{H}_{k+1} .

$$\mathbf{H}_{k+1} = \mathbf{V}_k^T \mathbf{H}_k \mathbf{V}_k + \rho_k \mathbf{s}_k \mathbf{s}_k^T \quad (4.22)$$

dimana

$$\rho_k = \frac{1}{\mathbf{y}_k^T \mathbf{s}_k}; \mathbf{V}_k = \mathbf{I} - \rho_k \mathbf{y}_k \mathbf{s}_k^T; \{\mathbf{s}_i, \mathbf{y}_i\} = \{\mathbf{z}_{i+1} - \mathbf{z}_i, \nabla g(\mathbf{z}_{i+1}) - \nabla g(\mathbf{z}_i)\}, i = k - \hat{m} + 1, \dots, k$$

sehingga persamaan (4.22) termodifikasi menjadi

$$\begin{aligned} \mathbf{H}_{k+1} &= \mathbf{V}_k^T \mathbf{H}_k \mathbf{V}_k + \rho_k \mathbf{s}_k \mathbf{s}_k^T = \mathbf{V}_k^T \left(\mathbf{V}_{k-1}^T \mathbf{H}_{k-1} \mathbf{V}_{k-1} + \rho_{k-1} \mathbf{s}_{k-1} \mathbf{s}_{k-1}^T \right) \mathbf{V}_k + \rho_k \mathbf{s}_k \mathbf{s}_k^T \\ &= \mathbf{V}_k^T \mathbf{V}_{k-1}^T \mathbf{H}_{k-1} \mathbf{V}_{k-1} \mathbf{V}_k + \rho_{k-1} \mathbf{V}_k^T \mathbf{s}_{k-1} \mathbf{s}_{k-1}^T \mathbf{V}_k + \rho_k \mathbf{s}_k \mathbf{s}_k^T. \end{aligned} \quad (4.23)$$

Karena $\mathbf{H}_{k-1} = \mathbf{V}_{k-2}^T \mathbf{H}_{k-2} \mathbf{V}_{k-2} + \rho_{k-2} \mathbf{s}_{k-2} \mathbf{s}_{k-2}^T$, maka persamaan (4.23) menjadi

$$\begin{aligned} \mathbf{H}_{k+1} &= \mathbf{V}_k^T \mathbf{V}_{k-1}^T \left(\mathbf{V}_{k-2}^T \mathbf{H}_{k-2} \mathbf{V}_{k-2} + \rho_{k-2} \mathbf{s}_{k-2} \mathbf{s}_{k-2}^T \right) \mathbf{V}_{k-1} \mathbf{V}_k + \rho_{k-1} \mathbf{V}_k^T \mathbf{s}_{k-1} \mathbf{s}_{k-1}^T \mathbf{V}_k + \\ &\quad \rho_k \mathbf{s}_k \mathbf{s}_k^T \\ &= \mathbf{V}_k^T \mathbf{V}_{k-1}^T \mathbf{V}_{k-2}^T \mathbf{H}_{k-2} \mathbf{V}_{k-2} \mathbf{V}_{k-1} \mathbf{V}_k + \rho_{k-1} \mathbf{V}_k^T \mathbf{V}_{k-1}^T \mathbf{s}_{k-2} \mathbf{s}_{k-2}^T \mathbf{V}_{k-1} \mathbf{V}_k + \\ &\quad \rho_{k-1} \mathbf{V}_k^T \mathbf{s}_{k-1} \mathbf{s}_{k-1}^T \mathbf{V}_k + \rho_k \mathbf{s}_k \mathbf{s}_k^T. \end{aligned} \quad (4.24)$$

Berdasarkan persamaan (4.22), (4.23), dan (4.24), berlaku persamaan umum (4.25) untuk mencari \mathbf{H}_{k+1} .

$$\begin{aligned} \mathbf{H}_{k+1} &= \left(\mathbf{V}_k^T \mathbf{V}_{k-1}^T \cdots \mathbf{V}_{k-\bar{m}+1}^T \right) \mathbf{H}_{k-\bar{m}+1} \left(\mathbf{V}_{k-\bar{m}+1} \cdots \mathbf{V}_{k-1} \mathbf{V}_k \right) + \\ &\quad \rho_{k-\bar{m}+1} \left(\mathbf{V}_{k-1}^T \mathbf{V}_{k-2}^T \cdots \mathbf{V}_{k-\bar{m}+2}^T \right) \mathbf{s}_{k-\bar{m}+1} \mathbf{s}_{k-\bar{m}+1}^T \left(\mathbf{V}_{k-\bar{m}+2} \cdots \mathbf{V}_{k-2} \mathbf{V}_{k-1} \right) + \dots + \\ &\quad \rho_{k-1} \mathbf{V}_k^T \mathbf{s}_{k-1} \mathbf{s}_{k-1}^T \mathbf{V}_k + \rho_k \mathbf{s}_k \mathbf{s}_k^T. \end{aligned} \quad (4.25)$$

5. Kembali ke langkah 2 agar mendapatkan $\Delta \mathbf{z}_k$ dan memperbarui \mathbf{z}_{k+1} untuk memeriksa konvergensi iterasi dengan $k = k + 1$.


4.3 Aplikasi BMA dan GOP untuk Prakiraan Cuaca Jangka Pendek Terkalibrasi di 8 Stasiun Meteorologi Jabodetabek

Setelah mengkaji proses untuk mendapatkan estimator parameter BMA dan GOP, maka langkah berikutnya adalah mengaplikasikan kedua model tersebut dalam kasus prakiraan cuaca di beberapa stasiun meteorologi (stamet) Jabodetabek. Sub-bab ini menjelaskan mengenai tahapan pra-pemrosesan, yaitu standarisasi dan reduksi dimensi dengan PCA, pembentukan anggota ensemble dengan regresi PLS, PCR dan Ridge sebelum suhu udara dimodelkan dengan BMA dan GOP, hingga pemeriksaan dan perbandingan kebaikan ramalan BMA dan GOP. Secara umum, sebagian besar analisis dan uraian dikhususkan untuk stamet Dermaga di Kabupaten Bogor, Jawa Barat. Sementara, hasil luaran atau *output* yang lebih detail disajikan pada Lampiran 1-52.

4.3.1. Analisis Deskripsi Suhu Udara dan Standarisasi

Sebelum memulai pra-pemrosesan data, dilakukan analisis deskripsi secara visual untuk mendapatkan gambaran umum dari pola cuaca, yaitu suhu udara. Gambar 4.1 menampilkan tren pergerakan suhu maksimum dan suhu minimum di stamet Dermaga. Hal ini dilakukan untuk melihat bagaimana pola umum dari suhu

maksimum (T_{MAKS}), suhu minimum (T_{MIN}) selama periode 708 hari pengamatan, yaitu 1 Januari 2009 hingga 31 Desember 2010.



Gambar 4.1 Observasi Suhu Maksimum dan Suhu Minimum di Stamet Dermaga

Di stamet Dermaga, suhu maksimum dan suhu minimum pada umumnya tidak menunjukkan adanya gejala yang menyimpang cukup jauh, meskipun nilai keduanya pada hari-hari tertentu berada pada angka yang jauh lebih rendah dibandingkan hari sebelumnya. Tren suhu maksimum (berwarna biru) dan tren suhu minimum (berwarna merah) pada Gambar 4.1 mengindikasikan bahwa pergerakan harian kedua elemen cuaca tersebut adalah fluktuatif selama 708 hari pengamatan. Selain itu, jika suhu minimum menunjukkan perubahan yang signifikan (kenaikan/penurunan yang drastis), maka pola yang hampir sama diindikasikan turut terjadi pada suhu maksimum.

Setelah mendeskripsikan suhu maksimum dan suhu minimum secara visual, langkah berikutnya ialah pra-pemrosesan parameter NWP dengan PCA. Namun sebelum melakukan PCA, diterapkan terlebih dulu standardisasi terhadap respon (suhu udara) dan parameter NWP berdasarkan metode *scaled and centered*, yaitu nilai pengamatan dikurangi mean lalu dibagi standar deviasi. Standardisasi respon menggunakan mean dan deviasi standar pada Lampiran 1, sementara standardisasi parameter NWP menggunakan mean dan standar deviasi pada Lampiran 2-9. Jadi, banyak komponen utama yang digunakan dalam pemodelan ke depannya diperoleh dari data yang distandarkan (bukan data asli). Hal ini bertujuan untuk meminimalkan perbedaan skala pengukuran antar parameter NWP.

4.3.2. Pra-pemrosesan Parameter NWP dengan PCA

Tahap ini dilakukan untuk mengetahui keterkaitan antar grid sebab terdapat indikasi bahwa kondisi atmosfer dipengaruhi oleh hubungan spasial antar elemen cuaca pembentuk atmosfer. Misal kejadian cuaca tertentu di daerah Dermaga memiliki kemungkinan dipengaruhi oleh kejadian cuaca yang sedang atau baru saja berakhir di lokasi yang terdekat dengan Dermaga. Oleh karena itu, pra-pemrosesan parameter NWP dengan PCA bertujuan untuk mereduksi hubungan spasial antar grid ke dalam beberapa komponen utama. Selain itu, dengan mengetahui hubungan yang terbentuk antar grid, maka parameter yang ada dapat direduksi (reduksi dimensi), sehingga menyederhanakan pemodelan dan diharapkan mampu mempersingkat proses komputasi tanpa mengorbankan akurasi dan presisi peramalan. Tabel 4.1 menyajikan nilai eigen dan kumulatif varians (dalam persen) salah satu variabel NWP yaitu presipitasi (rnd).

Tabel 4.1 Nilai Eigen dan Kumulatif Varians (%) PC Variabel Presipitasi (rnd)

PC ke-	Cengkareng		Citeko		Curug		Dermaga	
	Nilai eigen	Kum. varians	Nilai eigen	Kum. varians	Nilai eigen	Kum. varians	Nilai eigen	Kum. varians
1	7,350*	81,66%	7,920*	88,00%	8,003*	88,92%	7,359*	81,76%
2	0,995	92,72%	0,442	92,91%	0,548	95,00%	0,788	90,52%
3	0,348	96,59%	0,386	97,19%	0,299	98,33%	0,580	96,96%
4	0,170	98,48%	0,113	98,45%	0,075	99,17%	0,160	98,74%
5	0,077	99,34%	0,061	99,13%	0,034	99,55%	0,051	99,30%
6	0,031	99,68%	0,039	99,56%	0,019	99,76%	0,031	99,65%
7	0,021	99,91%	0,020	99,79%	0,011	99,88%	0,023	99,91%
8	0,006	99,98%	0,016	99,97%	0,009	99,99%	0,007	99,98%
9	0,002	100,00%	0,003	100,00%	0,001	100,00%	0,001	100,00%

PC ke-	Kemayoran		Pondok Betung		Priok		Tangerang	
	Nilai eigen	Kum. varians	Nilai eigen	Kum. varians	Nilai eigen	Kum. varians	Nilai eigen	Kum. varians
1	7,682*	85,36%	7,943*	88,26%	7,085*	78,72%	7,856*	87,29%
2	0,655	92,64%	0,478	93,57%	1,213*	92,20%	0,645	94,45%
3	0,317	96,17%	0,262	96,48%	0,378	96,39%	0,323	98,05%
4	0,153	97,87%	0,148	98,13%	0,137	97,92%	0,091	99,06%
5	0,080	98,76%	0,103	99,28%	0,076	98,76%	0,046	99,57%
6	0,057	99,39%	0,030	99,61%	0,059	99,41%	0,017	99,77%
7	0,032	99,75%	0,023	99,87%	0,031	99,76%	0,012	99,90%
8	0,020	99,97%	0,010	99,98%	0,019	99,97%	0,007	99,98%
9	0,003	100,00%	0,002	100,00%	0,003	100,00%	0,002	100,00%

Ket. : * adalah komponen dengan nilai eigen > 1 dan kumulatif varians minimal 80%

Berdasarkan Tabel 4.1, varians presipitasi di Dermaga yang dapat dijelaskan oleh komponen pertama sebesar 81,76%. Tingginya kumulatif varians yang dicapai hanya oleh komponen pertama saja mengindikasikan bahwa presipitasi memiliki keterkaitan yang tinggi antar grid (lokasi). Artinya, hujan yang terjadi (diukur berdasarkan besar curah hujan) di daerah Dermaga turut berpengaruh pula pada lokasi-lokasi terdekat. Atau sebaliknya, hujan di daerah Dermaga dipengaruhi oleh hujan di daerah sekitar, misal Citeko yang hanya terpisah 10 km saja. Selain itu, varians presipitasi di seluruh delapan stasiun meteorologi yang dapat dijelaskan oleh PCA berkisar antara 81,66% (stamet Cengkareng) hingga 92,20% (stamet Priok) dimana tingginya keragaman variabel presipitasi telah dapat dijelaskan oleh satu atau dua komponen saja.

Sebagai informasi, kriteria untuk menentukan banyaknya komponen utama ialah berdasarkan nilai eigen yang lebih besar dari atau sama dengan 1 (satu) dan mencapai kumulatif varians minimal 80%. Dengan menerapkan langkah yang sama menggunakan Lampiran 55a, diperoleh komponen-komponen yang merepresentasikan parameter NWP di stamet Dermaga dan disajikan pada Tabel 4.2. Sementara, banyaknya PC terpilih untuk parameter NWP di tujuh stamet lainnya disajikan pada Lampiran 10-16.

Tabel 4.2 Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Dermaga

Variabel	Byk. PC	Nilai Eigen	Kum. Varians	Variabel	Byk. PC	Nilai Eigen	Kum. Varians
dpsdt	1	8,998	99,98%	rh1	2	7,186; 1,182	92,98%
mixr1	1	7,632	84,80%	rh2	1	8,253	91,70%
mixr2	1	8,367	92,96%	rh4	1	8,591	95,45%
mixr4	1	8,618	95,76%	rnd	1	7,359	81,76%
omega1	2	5,832; 2,138	88,56%	temp1	1	7,943	88,25%
omega2	2	5,597; 2,266	87,37%	temp2	1	8,381	93,13%
omega4	2	6,299; 1,273	84,13%	temp4	1	8,753	97,26%
pblh	1	7,483	83,15%	tmaxscr	1	8,640	96%
ps	1	8,529	94,77%	tminscr	1	7,542	83,80%
psl	1	8,960	99,95%	tpan	1	7,975	88,61%
qgscrn	2	6,651; 1,104	86,17%	tscrn	1	7,984	88,72%

Tabel 4.2 (lanjutan) Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Dermaga

Variabel	Byk. PC	Nilai Eigen	Kum. Varians	Variabel	Byk. PC	Nilai Eigen	Kum. Varians
u1	1	7,507	83,41%	v2	2	6,850; 1,136	88,74%
u2	1	8,012	89,02%	v4	1	8,607	95,64%
u4	1	8,877	98,63%	zg1	1	8,780	97,55%
ustar	2	6,014; 1,393	82,29%	zg2	1	7,910	87,89%
v1	2	6,371; 1,482	87,25%	zg4	2	5,057; 3,814	98,57%

Berdasarkan Tabel 4.2, diindikasikan bahwa 1 komponen sudah sangat baik dalam merepresentasikan sebagian parameter NWP di stamet Dermaga. Namun demikian, terdapat cukup banyak parameter NWP yang diwakili oleh 2 komponen, diantaranya seluruh parameter omega dan parameter ustar. Dengan demikian, reduksi dimensi PCA menghasilkan total 41 komponen dari 32 parameter NWP.

Kumulatif varians parameter NWP yang dijelaskan oleh komponen utama ialah berbeda-beda, mulai dari 81,76% hingga mendekati 100%. Jadi, keterkaitan antar grid dalam satu parameter NWP relatif tinggi sehingga reduksi dimensi diindikasikan sebagai langkah yang cukup tepat untuk mengkoreksi bias luaran NWP. Komponen-komponen utama yang merepresentasikan tiap parameter NWP untuk 7 stamet lainnya disajikan pada Lampiran 10-16. Berikutnya, 35 komponen utama yang terbentuk dari seluruh parameter NWP akan digunakan sebagai variabel prediktor dalam pemodelan MOS menggunakan regresi PLS, PCR dan Ridge, khususnya untuk stamet Dermaga.

4.3.3. Pembentukan Model Prakiraan Anggota Ensemble untuk Suhu Maksimum dan Suhu Minimum

Setelah mengetahui banyaknya komponen yang digunakan sebagai prediktor, maka langkah berikutnya adalah mendapatkan prakiraan anggota ensemble berdasarkan regresi PLS, PCR dan Ridge. Untuk regresi PLS dan PCR, sebelum dimodelkan, dilakukan penentuan banyak komponen yang optimal menggunakan PRESS. Sementara, untuk regresi Ridge, dilakukan pemilihan koefisien penalti λ dengan menggunakan pendekatan intuitif grafis. Sebagai

informasi, respon suhu udara dimodelkan dengan pendekatan univariat. Stamet yang dipilih sebagai ilustrasi untuk dijelaskan lebih rinci ialah Dermaga. Sementara, hasil luaran untuk stasiun cuaca lainnya disajikan pada Lampiran 17- Lampiran 40 sebab langkah pengerjaan yang digunakan adalah serupa.

4.3.3.1. Regresi PLS untuk Suhu Maksimum dan Suhu Minimum

Sebelum melakukan pemodelan PLS untuk T_{MAKS} dan T_{MIN} , langkah pertama yang dilakukan adalah menetapkan jumlah komponen yang optimal dari 41 komponen untuk membangkitkan model prakiraan cuaca pada stamet Dermaga. Berikutnya, melakukan validasi silang untuk menentukan jumlah komponen yang optimal di setiap iterasi model. Proses validasi silang di setiap iterasi akan menghasilkan nilai PRESS. Nilai PRESS digunakan sebagai acuan dalam pemilihan jumlah komponen yang optimal untuk suatu model. PLS atau secara khusus PLS1 merupakan salah satu pemodelan univariat, sehingga validasi silang menggunakan PRESS dilakukan untuk tiap respon.

Ketika satu komponen dibangkitkan, nilai PRESS model tersebut dihitung. Proses ini berlanjut hingga mencapai banyaknya komponen yang maksimum dapat dibangkitkan. Setelah seluruh komponen dibangkitkan, jumlah komponen optimal ditetapkan berdasarkan nilai PRESS terendah. Nilai PRESS dari 35 komponen pada stamet Dermaga untuk respon suhu maksimum T_{MAKS} dan suhu minimum T_{MIN} dihitung berdasarkan algoritma validasi silang Kernel PLS pada Lampiran 55b, disajikan pada Tabel 4.3.

Tabel 4.3 Nilai PRESS Model PLS Stamet Dermaga

	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS
T_{MAKS}	1	0,763	15	0,641	29	0,643
	2	0,708	16	0,641	30	0,643
	3	0,668	17	0,641	31	0,642
	4	0,657	18	0,642	32	0,642
	5	0,651	19	0,642	33	0,643
	6	0,649	20	0,643	34	0,643
	7	0,648	21	0,642	35	0,643
	8	0,647	22	0,644	36	0,643
	9	0,646	23	0,644	37	0,644
	10	0,643	24	0,645	38	0,644
	11	0,645	25	0,644	39	0,644
	12	0,643	26	0,644	40	0,644
	13	0,642	27	0,643	41	0,645
	14	0,643	28	0,643		

Tabel 4.3 (lanjutan) Nilai PRESS Model PLS Stamet Dermaga

	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS
T_{MIN}	1	0,900	15	0,894	29	0,891
	2	0,884	16	0,895	30	0,891
	3	0,881	17	0,897	31	0,893
	4	0,882	18	0,897	32	0,892
	5	0,883	19	0,898	33	0,892
	6	0,884	20	0,900	34	0,892
	7	0,885	21	0,900	35	0,891
	8	0,890	22	0,898	36	0,893
	9	0,891	23	0,896	37	0,892
	10	0,891	24	0,896	38	0,892
	11	0,892	25	0,896	39	0,891
	12	0,892	26	0,895	40	0,892
	13	0,892	27	0,891	41	0,890
	14	0,894	28	0,891		

Tabel 4.3 menunjukkan nilai PRESS di tiap tahap iterasi pada proses regresi PLS dengan menggunakan data validasi. Nilai PRESS terendah untuk suhu maksimum terdapat pada model PLS dengan 16 komponen, yaitu model dengan nilai PRESS sebesar 0,641. Dapat dikatakan bahwa model PLS yang optimal untuk meramalkan suhu maksimum diwakili oleh komponen yang cukup banyak. Berdasarkan Wold, Sjöström, dan Eriksson (2001), pemilihan komponen yang hampir mencapai maksimum banyaknya komponen sebaiknya dihindari. Hal ini dapat menyebabkan reduksi dimensi sebagai tujuan utama justru tidak tercapai.

Selain itu, terdapat kontradiksi jumlah komponen optimal antara suhu maksimum dan suhu minimum. Jika model PLS untuk suhu maksimum diindikasikan lebih optimal bila menggunakan komponen laten yang relatif banyak, namun sebaliknya model PLS untuk suhu minimum hanya memerlukan 3 komponen saja. Namun demikian, tetap diputuskan bahwa jumlah komponen laten yang digunakan adalah 16 dan 3, masing-masing untuk suhu maksimum dan suhu minimum. Nilai PRESS untuk 7 stamet lainnya disajikan pada Lampiran 17-23. Banyak komponen yang optimal bagi pemodelan T_{MAKS} dan T_{MIN} untuk regresi PLS di delapan stasiun disajikan pada Tabel 4.4.

Tabel 4.4 Jumlah Komponen Optimal Model PLS pada Delapan Stasiun

	Stamet	Banyak Komponen	PRESS Terendah	Stamet	Banyak Komponen	PRESS Terendah
T_{MAKS}	Cengkareng	7	0,702	Kemayoran	9	0,718
	Citeko	11	0,729	Pd. Betung	27	0,714
	Curug	17	0,706	Priok	8	0,755
	Dermaga	16	0,641	Tangerang	11	0,707

Tabel 4.4 (lanjutan) Jumlah Komponen Optimal Model PLS pada Delapan Stasiun

	Stamet	Banyak Komponen	PRESS Terendah	Stamet	Banyak Komponen	PRESS Terendah
T_{MIN}	Cengkareng	3	0,892	Kemayoran	6	0,863
	Citeko	8	0,802	Pd. Betung	6	0,901
	Curug	6	0,760	Priok	6	0,874
	Dermaga	3	0,881	Tangerang	2	0,948

Berdasarkan Tabel 4.4, 27 komponen laten akan digunakan untuk menduga T_{MAKS} pada stamet Pondok Betung dimana jumlah komponen laten yang digunakan untuk pemodelan PLS ialah yang terbanyak dibandingkan stamet lainnya. Tingginya komponen laten yang optimal ini mengindikasikan bahwa keadaan cuaca yang mempengaruhi suhu maksimum di Pondok Betung tidak saling bergantung antara parameter satu dengan yang lainnya, misal curah hujan dan arah angin hampir saling independen.

Selain itu, terdapat indikasi bahwa korelasi yang tinggi antar parameter cuaca turut mempengaruhi observasi suhu maksimum untuk stamet yang berada di Jakarta, seperti Priok dan Kemayoran (dilihat dari rendahnya komponen yg optimal). Hal ini menyiratkan bahwa keadaan cuaca di kedua wilayah tersebut cukup dinamis. Sementara, hampir seluruh stamet yang berada di wilayah Bogor dan Banten menunjukkan pola cuaca yang lebih statis (dilihat dari tingginya komponen yang optimal).

Namun, Tabel 4.4 menunjukkan bahwa model PLS untuk suhu minimum tidak memerlukan komponen laten yang sangat banyak jika dibandingkan untuk suhu maksimum, ditambah persebaran banyak komponen yang lebih *uniform* (seragam). Tetapi, PRESS suhu minimum pada tiap relatif lebih tinggi daripada PRESS suhu maksimum. Hal demikian dapat menyebabkan prakiraan T_{MIN} menjadi sedikit tidak stabil jika ada observasi cuaca terbaru.

Setelah jumlah komponen yang optimal pada tiap stasiun diperoleh dan digunakan sebagai komponen-komponen laten yang berkontribusi bagi pemodelan, langkah berikutnya ialah melakukan regresi PLS untuk prakiraan T_{MAKS} dan T_{MIN} . Tabel 4.5 berikut merupakan koefisien regresi dalam bentuk standarisasi untuk model PLS T_{MAKS} dan T_{MIN} di stamet Dermaga.

Tabel 4.5 Koefisien Regresi Model PLS Stamet Dermaga

Var. Prediktor	T_{MAKS}	T_{MIN}	Var. Prediktor	T_{MAKS}	T_{MIN}
PC.dpsdt	-0,112	0,003	PC.tmaxscr	-0,538	0,060
PC.mixr1	0,130	0,093	PC.tminscr	-0,128	-0,073
PC.mixr2	0,139	-0,077	PC.tpan	0,092	-0,005
PC.mixr4	0,034	0,054	PC.tscrn	-0,169	-0,021
PC1.omega1	0,195	0,012	PC.u1	-0,434	-0,002
PC2.omega1	0,288	0,005	PC.u2	-0,415	0,014
PC1.omega2	-0,144	0,006	PC.u4	0,169	0,023
PC2.omega2	-0,040	0,008	PC1.ustar	0,081	0,051
PC1.omega4	-0,035	-0,008	PC2.ustar	0,013	-0,033
PC2.omega4	-0,064	0,044	PC1.v1	0,049	-0,008
PC.pblh	-0,019	0,048	PC2.v1	0,028	-0,0004
PC.ps	0,022	0,020	PC1.v2	-0,139	-0,007
PC.psl	0,026	0,023	PC2.v2	0,106	-0,007
PC1.qgscrn	-0,038	-0,089	PC.v4	-0,009	-0,027
PC2.qgscrn	-0,081	0,003	PC.zg1	-0,086	0,020
PC1.rh1	0,029	-0,060	PC.zg2	0,020	0,012
PC2.rh1	-0,061	-0,059	PC1.zg4	-0,0002	-0,059
PC.rh2	0,041	-0,045	PC2.zg4	0,067	0,060
PC.rh4	0,029	-0,009			
PC.rnd	0,073	-0,011			
PC.temp1	-0,115	-0,029			
PC.temp2	0,318	-0,043			
PC.temp4	0,017	-0,094			

Karena koefisien regresi pada Tabel 4.5 adalah koefisien terstandarkan, maka akan lebih mudah untuk membandingkan kontribusi masing-masing parameter NWP terhadap model. Dapat dikatakan bahwa model PLS T_{MIN} didominasi oleh koefisien yang mendekati nol. Hal sebaliknya justru terjadi pada model PLS T_{MAKS} yang lebih menyebar. Hal ini mengindikasikan bahwa kontribusi tiap parameter NWP terhadap model T_{MIN} relatif lebih seimbang.

Setelah koefisien regresi diperoleh pada tahap sebelumnya, maka langkah selanjutnya ialah membentuk model PLS berdasarkan koefisien regresi pada Tabel 4.5. Model prakiraan elemen cuaca T_{MAKS} dan T_{MIN} menggunakan metode PLS di stamet Dermaga disajikan pada Tabel 4.6.

Tabel 4.6 Model PLS untuk Prakiraan Cuaca Stamet Dermaga

$$\hat{y}_{T_{\text{MAKS}}} = -0,112PC.dpsdt + 0,13PC.mixr1 + 0,139PC.mixr2 + 0,034PC.mixr4 + 0,195PC1.omega1 + 0,288PC2.omega1 - 0,144PC1.omega2 - 0,04PC2.omega2 - 0,035PC1.omega4 + -0,064PC2.omega4 - 0,019PC.pblh + 0,022PC.ps + 0,026PC.psl - 0,038PC1.qgscrn + -0,081PC2.qgscrn + 0,029PC1.rh1 - 0,061PC2.rh1 + 0,041PC.rh2 + 0,029PC.rh4 + 0,073PC.rnd - 0,115PC.temp1 + 0,318PC.temp2 + 0,017PC.temp4 - 0,538PC.tmaxscr + -0,128PC.tminscr + 0,092PC.tpan - 0,169PC.tscrn - 0,434PC.u1 - 0,415PC.u2 + 0,169PC.u4 + 0,081PC1.ustar + 0,013PC2.ustar + 0,049PC1.v1 + 0,028PC2.v1 + -0,139PC1.v2 + 0,106PC2.v2 - 0,009PC.v4 - 0,086PC.zg1 + 0,02PC.zg2 + -0,0002PC1.zg4 + 0,067PC2.zg4$$

$$\hat{y}_{T_{\text{MIN}}} = 0,003PC.dpsdt + 0,093PC.mixr1 - 0,077PC.mixr2 + 0,054PC.mixr4 + 0,012PC1.omega1 + 0,005PC2.omega1 + 0,006PC1.omega2 + 0,008PC2.omega2 - 0,008PC1.omega4 + 0,044PC2.omega4 + 0,048PC.pblh + 0,02PC.ps + 0,023PC.psl - 0,089PC1.qgscrn + 0,003PC2.qgscrn - 0,06PC1.rh1 - 0,059PC2.rh1 - 0,045PC.rh2 - 0,009PC.rh4 + -0,011PC.rnd - 0,029PC.temp1 - 0,043PC.temp2 - 0,094PC.temp4 + 0,06PC.tmaxscr + -0,073PC.tminscr - 0,005PC.tpan - 0,021PC.tscrn - 0,002PC.u1 + 0,014PC.u2 + 0,023PC.u4 + 0,051PC1.ustar - 0,033PC2.ustar - 0,008PC1.v1 - 0,0004PC2.v1 + -0,007PC1.v2 - 0,007PC2.v2 - 0,027PC.v4 + 0,02PC.zg1 + 0,012PC.zg2 + -0,059PC1.zg4 + 0,06PC2.zg4$$

Model PLS pada Tabel 4.6 adalah model yang masih memuat komponen utama (PC). Model yang mewakili sembilan grid hanya bisa diperoleh jika tiap komponen utama pada Tabel 4.6 dipartisi, yaitu dengan mengalikan skor komponen utama terhadap tiap vektor eigennya. Matriks vektor eigen berukuran $s \times k$ dengan s adalah banyak grid dan k adalah banyak komponen utama. Berikut ini merupakan ringkasan vektor eigen untuk tiap 41 komponen pada stamet Dermaga dengan kolom pertama menunjukkan vektor eigen untuk *dpsdt*, begitu seterusnya hingga kolom terakhir untuk *zg4*.

$$\mathbf{E} = \begin{bmatrix} \text{dpsdt} & \text{mixr1} & \text{mixr2} & \text{mixr4} & \dots & \text{rnd} & \dots & \text{zg4} & \text{zg4} \\ -0,333 & 0,341 & -0,335 & 0,334 & \dots & -0,334 & \dots & -0,201 & 0,452 \\ -0,333 & 0,322 & -0,334 & 0,335 & \dots & -0,339 & \dots & -0,396 & -0,228 \\ -0,333 & 0,313 & -0,324 & 0,330 & \dots & -0,319 & \dots & -0,440 & 0,019 \\ -0,333 & 0,349 & -0,340 & 0,337 & \dots & -0,351 & \dots & -0,070 & 0,504 \\ -0,333 & 0,356 & -0,343 & 0,340 & \dots & -0,364 & \dots & -0,439 & -0,063 \\ -0,333 & 0,348 & -0,339 & 0,335 & \dots & -0,337 & \dots & -0,408 & 0,194 \\ -0,333 & 0,327 & -0,326 & 0,323 & \dots & -0,312 & \dots & 0,103 & 0,498 \\ -0,333 & 0,323 & -0,328 & 0,334 & \dots & -0,328 & \dots & -0,250 & -0,422 \\ -0,333 & 0,317 & -0,330 & 0,332 & \dots & -0,312 & \dots & -0,415 & 0,148 \end{bmatrix}$$

Berdasarkan matrik eigen vektor **E**, diindikasikan bahwa r_{nd} memiliki pengaruh yang negatif terhadap suhu udara. Hal ini mengimplikasikan bahwa curah hujan yang tinggi cenderung menyebabkan suhu berada pada kisaran yang rendah, begitu pula sebaliknya. Setelah memperoleh matriks eigen vektor dan mengalikannya dengan komponen utama yang bersesuaian, maka diperoleh model PLS untuk stamet Dermaga yang mewakili seluruh parameter NWP di sembilan grid pada Lampiran 24. Untuk mendapatkan prakiraan cuaca, model PLS pada Tabel 4.6 atau model yang lebih detail pada Lampiran 24 harus dikembalikan ke bentuk awal dengan mengalikannya terhadap standar deviasi lalu dijumlahkan mean (rata-rata) sesuai Lampiran 1. Secara ringkas, hasil prakiraan cuaca dari model PLS untuk seluruh 8 stamet disajikan pada Lampiran 25-26.

4.3.3.2. Regresi PCR untuk Suhu Maksimum dan Suhu Minimum

Serupa dengan regresi PLS, langkah yang sebaiknya dilakukan sebelum memodelkan cuaca dengan regresi PCR adalah menetapkan jumlah komponen yang optimal dari 41 komponen milik stamet Dermaga. Meskipun terdapat kesamaan dalam prosedur awal, namun PCR tidak memilih komponen optimal berdasarkan RMSE terendah seperti regresi PLS. Komponen terpilih adalah komponen yang mampu merepresentasikan keragaman prediktor minimal 80%. Artinya, pemilihan komponen optimal pada PCR didasari dari persentase kumulatif varians, alih-alih menggunakan kriteria PRESS.

Seperti PLS, PCR juga dapat diklasifikasikan untuk respon multivariat atau univariat. Namun untuk kasus ini, ditetapkan untuk memodelkan suhu udara dengan PCR univariat agar konsisten dengan regresi PLS sebelumnya yang juga dimodelkan dengan respon univariat. Tabel 4.7 menyajikan varians yang merepresentasikan keragaman prediktor pada stamet Dermaga. Varians terjelaskan untuk prediktor pada model PCR suhu maksimum dan suhu minimum adalah sama karena proses perhitungannya yang tidak melibatkan variabel respon.

Tabel 4.7 Kumulatif Varians 41 Komponen Prediktor Stamet Dermaga

Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians
1	23,78	15	95,24	29	99,86
2	38,73	16	96,01	30	99,91
3	50,97	17	96,74	31	99,94
4	60,04	18	97,30	32	99,96
5	66,72	19	97,79	33	99,97
6	72,88	20	98,23	34	99,98
7	77,43	21	98,59	35	99,99
8	81,81	22	98,92	36	99,99
9	85,06	23	99,16	37	100,0
10	87,60	24	99,35	38	100,0
11	89,95	25	99,50	39	100,0
12	91,68	26	99,62	40	100,0
13	93,00	27	99,71	41	100,0
14	94,16	28	99,79		
Keragaman T_{MAKS} menjelaskan				45%	
Keragaman T_{MIN} menjelaskan				22,43%	

Berdasarkan Tabel 4.7, 8 dari 41 komponen mampu untuk mewakili 80% lebih keragaman prediktor sehingga diputuskan bahwa banyak komponen yang optimal untuk model PCR suhu udara, baik T_{MAKS} maupun T_{MIN} , adalah 8. Seluruh 8 komponen tersebut dapat menjelaskan keragaman suhu maksimum sebesar 45%, sementara untuk suhu minimum hanya separuhnya saja yaitu 22,43%. Artinya, terdapat cukup banyak parameter cuaca di atmosfer atau permukaan bumi yang mempengaruhi suhu maksimum dan suhu minimum, selain 32 parameter NWP yang telah disebutkan pada Bab 3. Kumulatif varians untuk 7 stamet lainnya disajikan pada Lampiran 27-33. Banyak komponen optimal berdasarkan keragaman prediktor yang direpresentasikan oleh kumulatif varians disajikan pada Tabel 4.8.

Tabel 4.8 Jumlah Komponen Optimal PCR pada Delapan Stasiun

Stamet	Banyak Komponen	%Varians Prediktor	Stamet	Banyak Komponen	%Varians Prediktor
Cengkareng	9	82,97	Kemayoran	8	82,43
Citeko	8	82,48	Pd. Betung	8	81,09
Curug	7	80,93	Priok	10	81,99
Dermaga	8	81,81	Tangerang	8	81,68

Berdasarkan Tabel 4.8, 7 hingga 10 komponen diindikasikan telah merepresentasikan setidaknya 80% keragaman prediktor. Dapat dikatakan bahwa dinamika cuaca di daerah Priok relatif lebih dinamis dan pengaruh antar parameter nampak lebih independen (bebas), sedikit berkebalikan dengan dinamika cuaca di

daerah Curug yang berada di wilayah dataran tinggi. Setelah memperoleh komponen hasil PCA yang bebas multikolinearitas, maka komponen tersebut menjadi prediktor baru yang akan diregresikan terhadap T_{MAKS} dan T_{MIN} . Tabel 4.9 merupakan koefisien regresi dalam bentuk standarisasi untuk model PCR T_{MAKS} dan T_{MIN} di stamet Dermaga.

Tabel 4.9 Koefisien Regresi Model PCR Stamet Dermaga

Var. Prediktor	T_{MAKS}	T_{MIN}	Var. Prediktor	T_{MAKS}	T_{MIN}
PC.dpsdt	0,011	-0,006	PC.temp2	-0,049	-0,039
PC.mixr1	-0,028	0,087	PC.temp4	-0,028	-0,056
PC.mixr2	0,015	-0,063	PC.tmaxscr	-0,072	0,003
PC.mixr4	-0,012	0,064	PC.tminscr	-0,054	-0,056
PC1.omega1	0,004	-0,002	PC.tpan	-0,073	-0,030
PC2.omega1	0,036	0,007	PC.tscrn	-0,058	-0,016
PC1.omega2	0,009	0,0003	PC.u1	-0,108	-0,022
PC2.omega2	0,030	0,006	PC.u2	0,106	0,025
PC1.omega4	-0,009	-0,012	PC.u4	0,095	0,014
PC2.omega4	-0,002	0,006	PC1.ustar	-0,009	0,022
PC.pblh	-0,039	0,045	PC2.ustar	-0,022	-0,001
PC.ps	0,042	-0,023	PC1.v1	0,009	0,003
PC.psl	0,043	-0,021	PC2.v1	0,006	0,020
PC1.qgscrn	0,021	-0,084	PC1.v2	0,006	0,001
PC2.qgscrn	-0,012	-0,012	PC2.v2	0,008	-0,023
PC1.rh1	0,058	-0,059	PC.v4	-0,007	-0,021
PC2.rh1	0,011	-0,027	PC.zg1	-0,005	0,013
PC.rh2	0,037	-0,035	PC.zg2	-0,011	0,008
PC.rh4	0,024	-0,032	PC1.zg4	-0,038	-0,049
PC.rnd	0,051	-0,005	PC2.zg4	0,016	0,042
PC.temp1	-0,058	-0,021			

Karena koefisien regresi pada Tabel 4.9 adalah koefisien yang terstandarkan, maka akan lebih mudah untuk membandingkan kontribusi masing-masing parameter NWP terhadap model. Dapat dikatakan bahwa parameter model PCR, baik untuk suhu maksimum maupun suhu minimum, lebih banyak didominasi oleh koefisien yang mendekati nol. Keadaan yang berbeda terlihat pada model PLS sebelumnya dimana koefisien PLS untuk suhu maksimum relatif tinggi, meskipun koefisien PLS untuk suhu minimum lebih seragam dan bernilai mendekati 0. Hal ini mengindikasikan bahwa kontribusi tiap parameter NWP

terhadap model PCR lebih rendah daripada model PLS. Terdapat kemungkinan bahwa kondisi ini akan berpengaruh terhadap akurasi prakiraan cuaca.

Setelah koefisien regresi diperoleh pada tahap sebelumnya, maka langkah selanjutnya ialah membentuk model PCR berdasarkan koefisien regresi pada Tabel 4.9. Model prakiraan elemen cuaca T_{MAKS} dan T_{MIN} dengan menggunakan regresi PCR di stamet Dermaga disajikan pada Tabel 4.10.

Tabel 4.10 Model PCR untuk Prakiraan Cuaca Stamet Dermaga


$\hat{y}_{T_{\text{MAKS}}} = 0,011PC.dpsdt - 0,028PC.mixr1 + 0,015PC.mixr2 - 0,012PC.mixr4 + 0,004PC1.omega1 +$ $+ 0,036PC2.omega1 + 0,009PC1.omega2 + 0,03PC2.omega2 - 0,009PC1.omega4 +$ $- 0,002PC2.omega4 - 0,039PC.pblh + 0,042PC.ps + 0,043PC.psl + 0,021PC1.qgscrn +$ $- 0,012PC2.qgscrn + 0,058PC1.rh1 + 0,011PC2.rh1 + 0,037PC.rh2 + 0,024PC.rh4 +$ $+ 0,051PC.rnd - 0,058PC.temp1 - 0,049PC.temp2 - 0,028PC.temp4 - 0,072PC.tmaxscr +$ $- 0,054PC.tminscr - 0,073PC.tpan - 0,058PC.tscrn - 0,108PC.u1 + 0,106PC.u2 +$ $+ 0,095PC.u4 - 0,009PC1.ustar - 0,022PC2.ustar + 0,009PC1.v1 + 0,006PC2.v1 +$ $+ 0,006PC1.v2 + 0,008PC2.v2 - 0,007PC.v4 - 0,005PC.zg1 - 0,011PC.zg2 +$ $- 0,038PC1.zg4 + 0,016PC2.zg4$
$\hat{y}_{T_{\text{MIN}}} = -0,006PC.dpsdt + 0,087PC.mixr1 - 0,063PC.mixr2 + 0,064PC.mixr4 - 0,002PC1.omega1 +$ $+ 0,007PC2.omega1 + 0,0003PC1.omega2 + 0,006PC2.omega2 - 0,012PC1.omega4 +$ $+ 0,006PC2.omega4 + 0,045PC.pblh - 0,023PC.ps - 0,021PC.psl - 0,084PC1.qgscrn +$ $- 0,012PC2.qgscrn - 0,059PC1.rh1 - 0,027PC2.rh1 - 0,035PC.rh2 - 0,032PC.rh4 +$ $- 0,005PC.rnd - 0,021PC.temp1 - 0,039PC.temp2 - 0,056PC.temp4 + 0,003PC.tmaxscr +$ $- 0,056PC.tminscr - 0,03PC.tpan - 0,016PC.tscrn - 0,022PC.u1 + 0,025PC.u2 +$ $+ 0,014PC.u4 + 0,022PC1.ustar - 0,001PC2.ustar + 0,003PC1.v1 + 0,02PC2.v1 +$ $+ 0,001PC1.v2 - 0,023PC2.v2 - 0,021PC.v4 + 0,013PC.zg1 + 0,008PC.zg2 +$ $- 0,049PC1.zg4 + 0,042PC2.zg4$

Serupa dengan PLS, model PCR pada Tabel 4.10 memuat komponen utama (PC). Model PCR yang mewakili sembilan grid hanya bisa diperoleh jika tiap komponen utama pada Tabel 4.10 dipartisi, yaitu dengan mengalikan skor komponen utama terhadap tiap vektor eigennya. Matrik vektor eigen model PCR adalah sama dengan vektor eigen model PLS pada halaman 66. Setelah memperoleh matriks vektor eigen dan mengalikannya dengan komponen utama yang bersesuaian, maka model PCR untuk stamet Dermaga yang mewakili seluruh parameter NWP di sembilan grid disajikan pada Lampiran 34. Model PCR pada Tabel 4.10 atau model pada Lampiran 34 harus ditransformasi ke bentuk asal sehingga diperoleh suhu minimum pada kisaran 18°-25°C dan suhu maksimum pada kisaran 25°-35°C, yang disajikan pada Lampiran 35-36.

4.3.3.3. Regresi Ridge untuk Suhu Maksimum dan Suhu Minimum

Untuk melengkapi 2 anggota ensemble sebelumnya, dilakukan pemodelan cuaca dengan regresi lain yang mampu mereduksi efek multikolinearitas, yaitu regresi Ridge. Berbeda dengan 2 metode sebelumnya, metode ini tidak memerlukan pemilihan banyak komponen optimal. Metode ini menggunakan suatu konstanta λ untuk meminimalkan dampak dari singularitas $\mathbf{X}^T\mathbf{X}$.

Konstanta λ diharapkan untuk tidak bernilai sangat besar. Hal ini untuk menghindari koefisien regresi Ridge yang semakin mendekati 0. Jika terjadi, maka nilai dugaan dari respon juga turut mendekati 0. Padahal kenyataannya, suhu udara di Indonesia hampir tidak pernah berada pada kisaran 0° - 10°C . Untuk membantu penentuan konstanta λ , khususnya secara visual, maka diperlukan Gambar 4.2.



Gambar 4.2 Konvergensi Koefisien Regresi Ridge
(a) Suhu Maksimum; (b) Suhu Minimum

Penentuan konvergensi berdasarkan Gambar 4.2 seharusnya dihindari karena subjektif. Namun, pada kasus ini, konstanta λ bahkan tetap tidak konvergen saat λ mendekati 100 sehingga diputuskan untuk menggunakan

bantuan visual saja dalam menentukan λ . Berdasarkan Draper dan Smith (1992), penentuan batas bawah dan batas atas untuk λ tidak ditetapkan dengan ketat. Tetapi, sebaiknya batas atas tidak lebih besar daripada 10 atau 20 untuk menghindari koefisien regresi yang semakin tidak bermakna karena bernilai mendekati 0.

Dari Gambar 4.2, diindikasikan bahwa koefisien regresi untuk T_{MAKS} dan T_{MIN} konvergen saat λ sebesar 9 atau lebih. Tabel 4.11 adalah koefisien regresi Ridge untuk stamet Dermaga dengan $\lambda = 9$, sementara konstanta λ untuk tujuh stamet lainnya ditampilkan dalam Lampiran 37.

Tabel 4.11 Koefisien Regresi Ridge Stamet Dermaga

Var. Prediktor	T_{MAKS}	T_{MIN}	Var. Prediktor	T_{MAKS}	T_{MIN}
PC.dpsdt	-0,075	-0,099	PC.temp2	0,256	0,066
PC.mixr1	0,123	-0,125	PC.temp4	0,008	-0,219
PC.mixr2	0,102	-0,129	PC.tmaxscr	-0,513	0,149
PC.mixr4	0,030	0,008	PC.tminscr	-0,108	-0,084
PC1.omega1	0,153	0,165	PC.tpan	0,053	-0,026
PC2.omega1	0,212	0,015	PC.tscrn	-0,099	-0,010
PC1.omega2	-0,099	-0,051	PC.u1	-0,301	0,055
PC2.omega2	-0,029	-0,038	PC.u2	-0,236	0,016
PC1.omega4	-0,017	0,083	PC.u4	0,141	0,124
PC2.omega4	-0,082	0,031	PC1.ustar	0,048	0,014
PC.pblh	-0,041	0,010	PC2.ustar	0,007	-0,088
PC.ps	0,024	0,037	PC1.v1	-0,012	-0,075
PC.psl	0,027	0,066	PC2.v1	0,012	-0,049
PC1.qgscrn	-0,005	-0,153	PC1.v2	-0,094	0,010
PC2.qgscrn	-0,067	0,054	PC2.v2	0,089	0,053
PC1.rh1	0,027	-0,021	PC.v4	-0,032	-0,021
PC2.rh1	-0,069	-0,172	PC.zg1	-0,096	0,004
PC.rh2	0,031	-0,261	PC.zg2	0,022	-0,166
PC.rh4	0,037	0,009	PC1.zg4	0,001	0,022
PC.rnd	0,071	-0,022	PC2.zg4	0,079	0,290
PC.temp1	-0,108	-0,083			

Karena koefisien regresi pada Tabel 4.11 masih dalam bentuk standarisasi, maka akan lebih mudah untuk membandingkan kontribusi masing-masing parameter NWP terhadap model. Dapat dikatakan bahwa model Ridge T_{MIN} tidak lagi didominasi oleh koefisien yang mendekati nol, seperti pada regresi PLS dan regresi PCR. Hal ini mengindikasikan bahwa kontribusi beberapa parameter NWP

terhadap model T_{MIN} relatif lebih bermakna pada Ridge ketimbang PLS atau PCR. Kemungkinan hal ini dapat meningkatkan akurasi prakiraan cuaca atau justru tidak berpengaruh sama sekali.

Setelah koefisien regresi diperoleh pada tahap sebelumnya, maka langkah selanjutnya ialah membentuk model berdasarkan koefisien regresi pada Tabel 4.11. Model prakiraan elemen cuaca T_{MAKS} dan T_{MIN} menggunakan regresi Ridge di stamet Dermaga disajikan pada Tabel 4.12.

Tabel 4.12 Model Regresi Ridge untuk Prakiraan Cuaca Stamet Dermaga


$\hat{y}_{T_{MAKS}} = -0,075PC.dpsdt + 0,123PC.mixr1 + 0,102PC.mixr2 + 0,03PC.mixr4 + 0,153PC1.omega1 + 0,212PC2.omega1 - 0,099PC1.omega2 - 0,029PC2.omega2 - 0,017PC1.omega4 + -0,082PC2.omega4 - 0,041PC.pblh + 0,024PC.ps + 0,027PC.psl - 0,005PC1.qgscrn + -0,067PC2.qgscrn + 0,027PC1.rh1 - 0,069PC2.rh1 + 0,031PC.rh2 + 0,037PC.rh4 + 0,071PC.rnd - 0,108PC.temp1 + 0,256PC.temp2 + 0,008PC.temp4 - 0,513PC.tmaxscr + -0,108PC.tminscr + 0,053PC.tpan - 0,099PC.tscrn - 0,301PC.u1 - 0,236PC.u2 + 0,141PC.u4 + 0,048PC1.ustar + 0,007PC2.ustar - 0,012PC1.v1 + 0,012PC2.v1 + -0,094PC1.v2 + 0,089PC2.v2 - 0,032PC.v4 - 0,096PC.zg1 + 0,022PC.zg2 + 0,001PC1.zg4 + 0,079PC2.zg4$
$\hat{y}_{T_{MIN}} = -0,099PC.dpsdt - 0,125PC.mixr1 - 0,129PC.mixr2 + 0,008PC.mixr4 + 0,165PC1.omega1 + 0,015PC2.omega1 - 0,051PC1.omega2 - 0,038PC2.omega2 + 0,083PC1.omega4 + 0,031PC2.omega4 + 0,01PC.pblh + 0,037PC.ps + 0,066PC.psl - 0,153PC1.qgscrn + 0,054PC2.qgscrn - 0,021PC1.rh1 - 0,172PC2.rh1 - 0,261PC.rh2 + 0,009PC.rh4 + -0,022PC.rnd - 0,083PC.temp1 + 0,066PC.temp2 - 0,219PC.temp4 + 0,149PC.tmaxscr + -0,084PC.tminscr - 0,026PC.tpan - 0,01PC.tscrn + 0,055PC.u1 + 0,016PC.u2 + 0,124PC.u4 + 0,014PC1.ustar - 0,088PC2.ustar - 0,075PC1.v1 - 0,049PC2.v1 + 0,01PC1.v2 + 0,053PC2.v2 - 0,021PC.v4 + 0,004PC.zg1 - 0,166PC.zg2 + 0,022PC1.zg4 + 0,29PC2.zg4$

Dari Tabel 4.12, model Ridge masih memuat komponen utama (PC) sehingga untuk memperoleh model yang mewakili sembilan grid, tiap komponen utama pada Tabel 4.12 dipartisi, yaitu dengan mengalikan skor komponen utama terhadap tiap vektor eigennya. Matriks vektor eigen berukuran $s \times k$ dengan s adalah banyak grid dan k adalah banyak komponen utama. Untuk stamet Dermaga, matrik vektor eigen berukuran 9 x 41 sesuai dengan matrik E pada halaman 66. Setelah memperoleh matriks vektor eigen dan mengalikannya dengan komponen utama yang bersesuaian, maka model Ridge untuk stamet Dermaga yang mewakili seluruh parameter NWP di sembilan grid disajikan pada Lampiran 38. Untuk mengembalikan ke bentuk awal, prakiraan T_{MAKS} dan T_{MIN} dari Tabel

4.12 harus ditransformasi menggunakan mean dan deviasi standar berdasarkan Lampiran 1 dimana hasil prakiraan cuaca untuk seluruh 8 stamet ditampilkan dalam Lampiran 39-40.

4.3.4. Deskripsi Prakiraan Cuaca Anggota Ensemble

Setelah memperoleh model yang akan digunakan untuk meramalkan suhu udara, maka langkah berikutnya adalah membandingkan hasil ramalan tiap anggota ensemble dan nilai observasi. Pada kasus ini, anggota ensemble terdiri atas regresi PLS, PCR dan Ridge. Analisis deskriptif dilakukan dengan menggunakan plot runtun waktu untuk melihat seberapa baik ramalan anggota ensemble sebelum dikalibrasi oleh BMA. Gambar 4.3 dan Gambar 4.4 merupakan plot runtun waktu 100 hari pertama dari prakiraan ensemble dan observasi suhu udara untuk stamet Dermaga pada tahun 2009, masing-masing untuk suhu maksimum dan suhu minimum.




Gambar 4.3 Tren Prakiraan Anggota Ensemble dan Observasi Suhu Maksimum

Gambar 4.3 mengindikasikan bahwa tiap anggota ensemble, baik PLS, PCR maupun Ridge, telah dapat mengikuti pola umum dari suhu maksimum dimana jika tren suhu maksimum meningkat maka hasil prakiraan turut mengikuti naik, begitu pula sebaliknya jika tren suhu menurun. Namun, permasalahan yang timbul adalah kejadian *under-fitting* (ramalan berada di bawah nilai observasi) atau *over-*

fitting (ramalan berada di atas nilai observasi) yang konsisten terjadi di hari yang sama. Sebagai contoh, observasi suhu maksimum pada tanggal 1 Februari 2009 adalah 30°C. Sementara, ramalan PLS, PCR dan Ridge pada tanggal yang sama adalah 28,8°C, 29,6°C, dan 28,7°C. Jika diperhatikan, error yang dihasilkan berada dalam skala yang sedang sebab berada pada kisaran 0,3°C.

Meskipun ramalan ketiganya sudah mendekati nilai observasi, namun *under-fitting* yang terjadi secara serentak ini akan menyebabkan proses pembobotan BMA condong kepada hasil yang paling dekat dengan observasi, dalam hal ini 29,6°C milik PCR. Dengan demikian, bobot yang diberikan BMA untuk PCR pada tanggal 1 Februari 2009 kemungkinan besar mendekati 0,9. Sementara, bobot untuk kedua anggota ensemble lainnya kemungkinan tidak lebih besar dari 0,1. Untuk memperkuat analisis awal tentang kebaikan ramalan anggota ensemble, diperlukan pula identifikasi secara visual untuk suhu minimum yang disajikan pada Gambar 4.4, khususnya pada stamet Dermaga dalam 100 hari pertama pada tahun 2009.



Gambar 4.4 Tren Prakiraan Anggota Ensemble dan Observasi Suhu Minimum

Gambar 4.4 mengindikasikan fakta yang sama dengan Gambar 4.3 dimana ramalan anggota ensemble mampu untuk menangkap pola dan tren fluktuasi dari suhu minimum. Selain itu, kejadian *under-fitting* atau *over-fitting* juga serentak terjadi pada PLS, PCR dan Ridge pada sebagian besar hari pengamatan. Tetapi, dapat dikatakan bahwa permasalahan yang lebih kompleks terjadi pada suhu

minimum. Hal ini disebabkan musim penghujan tampaknya memiliki pengaruh yang cukup krusial terhadap tinggi rendahnya suhu minimum. Setelah musim beralih ke periode transisi, terlihat bahwa selisih yang lebar antara ramalan dan observasi yang sebelumnya cukup rutin terjadi sudah mengecil.

Meskipun ketiga anggota ensemble dapat menangkap pola suhu yang terjadi, namun ramalan yang dihasilkan cukup jauh dari observasi. Oleh karena itu, diperlukan kalibrasi model agar dihasilkan prakiraan cuaca yang lebih akurat dan presisi. Proses pembobotan BMA yang dilakukan secara iteratif dengan menggunakan *rolling training window* diharapkan dapat meminimalkan dampak dari *under-fitting* atau *over-fitting*, atau bahkan dampak dari pola musiman.


4.3.5. Kalibrasi Prakiraan Cuaca Menggunakan BMA

Berdasarkan sub-bab sebelumnya, diindikasikan bahwa hasil peramalan ensemble, khususnya untuk stamet Dermaga, masih memiliki akurasi yang cukup rendah, terutama untuk variabel suhu minimum. Oleh karena itu, diperlukan metode pemrosesan secara statistik untuk mengkalibrasi hasil peramalan agar bias ramalan menjadi lebih rendah. Kalibrasi dilakukan untuk melakukan penyesuaian terhadap varians, sehingga diperoleh ramalan yang lebih reliabel dengan varians yang proporsional dan memiliki interval prediksi yang lebih sempit.

Berdasarkan Raftery *et al.* (2005), dikatakan bahwa kalibrasi dengan BMA akan menghasilkan prakiraan yang lebih baik jika *ensemble range* memiliki korelasi yang signifikan dengan derajat kesalahan prakiraan. *Ensemble range* adalah selisih antara maksimum dan minimum dari suatu ensemble. Namun, korelasi yang signifikan tersebut belum tentu menjamin prakiraan ensemble sudah terkalibrasi dan tidak lagi *underdispersive* atau *overdispersive*. Pada penerapannya, kebanyakan prakiraan ensemble masih bersifat *underdispersive* yang dapat diidentifikasi dari *Verification Rank Histogram* (VRH).

Sebelum melangkah ke tahap tersebut, berikut ini disajikan Gambar 4.5, yaitu scatter plot antara *ensemble range* dan error mutlak. Hubungan yang diharapkan antara keduanya adalah sangat kuat dimana jika *ensemble range* makin kecil, maka diikuti pula dengan error prakiraan yang makin rendah, begitu sebaliknya. Sumbu X diwakili oleh range ensemble, yaitu rata-rata selisih antara

maksimum dan maksimum dari prakiraan ensemble. Sementara, sumbu Y diwakili oleh error mutlak, yaitu nilai mutlak dari selisih antara observasi dan mean ensemble. Mean ensemble merupakan rata-rata hasil prakiraan dari anggota ensemble yang dijumlahkan.




Gambar 4.5 Korelasi Ensemble Range terhadap Error Prakiraan, 1 Jan '09 – 30 Jan '09
(kiri) suhu maksimum (kanan) suhu minimum

Gambar 4.5 merupakan grafis yang mencerminkan hubungan antara prakiraan ensemble (sumbu X) dan bias/error prakiraan (sumbu Y) pada stamet Dermaga selama 30 hari *training*, dimulai dari 1 Januari 2009 hingga 30 Januari 2009. Gambar 4.5 mengindikasikan bahwa terdapat korelasi yang positif antara ensemble range dan error mutlak. Korelasi untuk suhu maksimum adalah sebesar 0,11, sementara untuk suhu minimum sebesar 0,24. Namun, penggunaan korelasi saja belum cukup untuk dapat menyimpulkan kebaikan prakiraan ensemble.

Jadi, dibutuhkan VRH seperti pada Gambar 4.6 untuk mengidentifikasi apakah prakiraan ensemble bersifat *underdispersive*, *overdispersive* atau *equidispersive*. Ensemble yang *underdispersive* dikenali dari histogram yang menyerupai U, sementara ensemble yang *overdispersive* dikenali dari histogram yang menyerupai kurva distribusi normal (Möller, 2014). Pada Gambar 4.6, sumbu horizontal adalah rank ke- i dimana $i = 1, \dots, 4$ atau sesuai dengan banyak

anggota ensemble dan satu observasi, sementara sumbu vertikal adalah kumulatif probabilitas Binomial dengan parameter n adalah total observasi dan p adalah $1/k$ dimana k adalah frekuensi observasi yang berada pada rank ke- i . Pada kasus ini, *raw ensemble* beranggotakan PLS, PCR, dan Ridge.



Gambar 4.6 VRH *Raw Ensemble* Stamet Dermaga, 1 Jan '09 – 30 Jan '09
(kiri) suhu maksimum (kanan) suhu minimum

Berdasarkan Gambar 4.6, terlihat bahwa prakiraan ensemble, baik suhu maksimum dan suhu minimum, masih bersifat *underdispersive* karena histogram untuk masing-masing unsur cuaca menyerupai bentuk U. Hal ini mengindikasikan bahwa masih banyak observasi suhu udara yang berada di luar *ensemble range*. Sebagai informasi, mekanisme VRH adalah dengan mengurutkan observasi suhu dan prakiraan anggota ensemble dari tertinggi hingga terendah (Hammill, 2001). Jika terdapat 3 anggota ensemble dimana observasi suhu pada 1 Februari 2009 lebih tinggi daripada prakiraan anggota ensemble, maka masuk ke dalam rank pertama, sebaliknya masuk rank keempat jika lebih rendah. Sementara, observasi terhitung masuk ke rank kedua dan ketiga jika berada dalam *ensemble range*.

Berdasarkan Gambar 4.6, diketahui bahwa *coverage* prakiraan ensemble untuk T_{MAKS} dan T_{MIN} masing-masing sebesar 20% dan 6,7%, dilihat berdasarkan persentase banyaknya observasi yang berada di rank kedua dan rank ketiga. Nilai *coverage* yang jauh berada di bawah standar, yaitu 50%, memperkuat keyakinan bahwa prakiraan ensemble MOS masih bersifat *underdispersive*. Hal ini dapat berpengaruh pada interval prediksi yang menjadi kurang presisi. Untuk mereduksi dampak *underdispersive*, diperlukan kalibrasi prakiraan ensemble, salah satunya

dengan BMA, sehingga interval prediksi yang dihasilkan menjadi lebih konsisten (tajam) dan reliabel.

Sebelum memulai analisis terhadap luaran BMA, seperti bobot, koefisien, dan sebagainya, terlebih dulu diberikan ilustrasi secara singkat pada Gambar 4.7 mengenai mekanisme *windowing* yang dilakukan oleh BMA dalam mengestimasi parameter model untuk suhu minimum pada stamet Dermaga dengan periode *training* selama 30 hari.

Tanggal	Observasi (°C)	Prakiraan Anggota Ensemble (°C)		
		PLS	PCR	Ridge
1/1/2009	23,2	22,37	22,45	22,39
2/1/2009	22,3	22,56	22,48	22,44
3/1/2009	21,2	21,88	21,81	21,99
4/1/2009	20,4	21,76	21,98	21,44
5/1/2009	19,8	22,05	22,14	22,02
6/1/2009	20,2	22,54	22,64	22,07
7/1/2009	21,8	22,72	22,71	22,70
29/1/2009	23	22,12	22,21	22,02
30/1/2009	22,8	22,26	22,22	22,25
31/1/2009	22,4	22,38	22,24	22,37
1/2/2009	22,5	22,30	22,39	22,20
2/2/2009	22,1	22,08	22,00	22,18

Banyak observasi yang digunakan untuk training adalah 30 hari

Gambar 4.7 Ilustrasi *Windowing* pada BMA

Berdasarkan Gambar 4.7, diketahui bahwa 30 hari pertama digunakan sebagai periode training untuk mengestimasi parameter regresi beserta bobot BMA untuk tanggal 31 Januari 2009. Untuk mengestimasi parameter BMA pada tanggal 1 Februari 2009, hari pertama dari 30 hari training tidak lagi digunakan atau dieliminasi dari *training window*. Begitu seterusnya hingga diperoleh prakiraan BMA untuk suhu minimum pada hari terakhir dalam periode testing, yaitu 2 Februari 2009. Dengan mekanisme ini, BMA mampu beradaptasi terhadap perubahan yang terjadi pada data ensemble, sehingga prakiraan yang dihasilkan tidak memiliki bias yang tinggi.

Langkah pertama yang dilakukan dalam pemodelan BMA adalah meregresikan tiap anggota ensemble terhadap observasi sehingga diperoleh koefisien bias regresi, yaitu $\beta_{0,m}$ dan $\beta_{1,m}$, untuk tiap anggota m . Koefisien ini

digunakan untuk mendapatkan prakiraan cuaca terkalibrasi, estimasi interval prediktif dan *coverage* BMA. Koefisien regresi dan bobot untuk 8 stamet disajikan secara singkat pada Lampiran 41-48. Sebagai contoh, Tabel 4.13 menyajikan koefisien regresi dan bobot tiap anggota ensemble m beserta mean BMA sebagai prakiraan tunggal dan observasi untuk stamet Dermaga pada tanggal 14 November 2009 berdasarkan training 30 hari. Tabel 4.13 diperoleh berdasarkan implementasi terhadap persamaan (4.6), (4.7), (4.14), dan (4.16) dan dieksekusi berdasarkan Lampiran 55c.

Tabel 4.13 Estimasi Parameter BMA untuk 14 November 2009 di Stamet Dermaga

Respon	Model	β_0	β_1	w	Prakiraan Anggota Ensemble (°C)	Obs. (°C)	BMA (°C)
T_{MAKS}	PLS	1,116	0,949	0,724	32,81		
	PCR	-3,314	1,087	0,276	32,24	32,6	32,9
	Ridge	0,892	0,957	0,000	32,75		
T_{MIN}	PLS	12,349	0,468	0,023	22,93		
	PCR	13,726	0,407	0,007	22,89	22,2	23,16
	Ridge	10,918	0,530	0,970	22,83		


Dari Tabel 4.13 di atas, dapat dilihat hasil estimasi parameter dan besarnya bobot dari tiap anggota ensemble. Untuk prakiraan suhu maksimum pada 14 November 2009, diindikasikan bahwa PLS memiliki kontribusi yang tertinggi terhadap model BMA karena bobot w sebesar 0,724, lebih tinggi daripada PCR maupun Ridge yang masing-masing memiliki bobot sebesar 0,276 dan 0. Artinya, Ridge hampir tidak memberikan kontribusi terhadap ramalan BMA yang sebesar 32,9 °C.

Namun sebaliknya, Ridge justru menjadi anggota ensemble yang berkontribusi paling tinggi terhadap model BMA untuk suhu minimum pada 14 November 2009. Hal ini terlihat dari bobot sebesar 0,97, mendekati nilai 1. Bobot Ridge bahkan jauh lebih besar daripada kedua model lainnya, yaitu 0,023 milik PLS dan 0,007 milik PCR. Dengan kata lain, kontribusi PLS dan PCR terhadap ramalan BMA untuk suhu minimum sebesar 23,16 °C sangat rendah.

Dari Tabel 4.13, diindikasikan bahwa akurasi ramalan BMA pada 14 November 2009 tidak berbeda signifikan dengan prakiraan ensemble. Namun,

perbedaan 1 °C antara observasi suhu minimum dan prakiraan BMA menunjukkan bahwa kasus *overfitting* yang serentak dialami oleh tiga prakiraan ensembel dapat berdampak pada berkurangnya akurasi ramalan BMA.

Tahap selanjutnya yang dilakukan adalah membentuk PDF prediktif BMA untuk kedua respon demi melihat seberapa baik kalibrasi yang dilakukan oleh BMA, ditunjukkan dari pergeseran PDF yang mendekati nilai observasi dan kurva PDF yang menyempit. Gambar 4.8 adalah PDF prediktif BMA untuk stamet Dermaga pada 14 November 2009.



Gambar 4.8 PDF Prediktif BMA Stamet Dermaga, 14 November 2009
(kiri) suhu maksimum (kanan) suhu minimum

Berdasarkan Gambar 4.8, terlihat bahwa nilai observasi (garis vertikal) untuk kedua suhu berada dalam interval prediktif 95% BMA (garis putus-putus). Hal ini mengindikasikan bahwa BMA menghasilkan interval yang reliabel, khususnya pada tanggal tersebut. Terlihat pula bahwa observasi suhu maksimum berada pada *ensemble range*, meskipun sebaliknya untuk suhu minimum. Hal ini dapat mempengaruhi PDF prediktif BMA sebab kalibrasi menjadi kurang optimal jika nilai observasi tidak berada dalam *ensemble range* (Raftery *et al.*, 2005).


Selain itu, Gambar 4.8 untuk suhu maksimum menunjukkan BMA mampu memperbaiki kelemahan dari PCR, terlihat dari kurva PDF BMA yang bergeser ke tengah untuk mendekati nilai observasi. Meski PDF BMA untuk suhu minimum justru melebar yang nampak mengurangi presisi, hal ini justru mengindikasikan bahwa varians yang awalnya terlalu rendah diupayakan menjadi sedikit lebih tinggi oleh BMA, namun tetap melingkupi nilai observasi. Hal ini menunjukkan kelebihan BMA yang dapat mereduksi *underdispersive*.

Kemudian, akan dibandingkan kebaikan ramalan antara BMA dan masing-masing anggota ensemble beserta NWP untuk stamet Dermaga dengan *training window* selama 30 hari, seperti ditunjukkan pada Tabel 4.14. Prakiraan BMA untuk suhu udara di 8 stamet, termasuk Dermaga, disajikan pada Lampiran 49-50.

Tabel 4.14 Perbandingan Kebaikan Prakiraan BMA dan Ensemble pada Stamet Dermaga 31 Jan '09 – 31 Des '10

	RMSE (°C)					CRPS		Coverage (%)	
	NWP	PLS	PCR	Ridge	BMA	<i>Raw Ensemble</i>	BMA	<i>Raw Ensemble</i>	BMA
T_{MAKS}	2,18	0,927	1,131	0,930	0,950	0,653	0,517	20,65	49,41
T_{MIN}	1,66	0,789	0,805	0,774	0,777	0,566	0,431	6,7	49,26

Dari Tabel 4.14, diindikasikan bahwa BMA mampu mengkoreksi bias NWP hingga lebih dari 50%. Namun dari perbandingan RMSE antara anggota ensemble dan BMA, dapat dikatakan bahwa BMA belum cukup signifikan untuk mampu meningkatkan akurasi prakiraan cuaca. Hal ini kemungkinan diakibatkan oleh pengaruh *overfitting* atau *underfitting* yang serentak terjadi dalam suatu hari *in-sample/training*, korelasi yang tidak signifikan antara observasi dan anggota ensemble, dan sebagainya. Namun demikian, BMA mampu menghasilkan interval prediktif yang lebih pendek daripada interval *raw ensemble* (sebelum dikalibrasi), berdasarkan CRPS yang lebih rendah.




Gambar 4.9 VRH BMA Stamet Dermaga, 31 Jan '09 – 31 Des '10
(kiri) suhu maksimum (kanan) suhu minimum

Berdasarkan *coverage* pada Tabel 4.14, dapat dikatakan bahwa BMA mampu mengkalibrasi prakiraan ensemble. Hal ini terlihat dari *coverage* BMA yang meningkat berkali-kali lipat dari sebelumnya, misal untuk suhu minimum dari 6,7% ke 49,26%, yang mendekati standar 50%. Gambar 4.9 mempertegas

bahwa BMA mampu mengkalibrasi prakiraan ensemble, khususnya untuk suhu minimum yang jelas memperlihatkan histogram yang lebih *uniform* daripada histogram *raw ensemble* sebelumnya pada Gambar 4.6.

4.3.6. Prakiraan Cuaca Berbasis Spasial Menggunakan GOP

Berdasarkan sub-bab sebelumnya, diindikasikan bahwa BMA sebagai pendekatan non-spasial dapat mengkalibrasi prakiraan ensemble dengan cukup baik, khususnya untuk stamet Dermaga, meskipun prakiraan yang dihasilkan belum akurat. Dengan menerapkan metode prakiraan cuaca berbasis spasial, diharapkan GOP dapat menangkap fenomena spasial yang terjadi, sehingga diperoleh prakiraan cuaca yang akurat dan juga reliabel. Gambar 4.10 merupakan ilustrasi tahapan yang ditempuh GOP untuk menghasilkan prakiraan cuaca, dengan respon adalah observasi elemen cuaca yang diteliti dan prediktor dapat berupa luaran NWP seperti suhu udara, kecepatan angin, dan sebagainya.



Gambar 4.10 Tahapan GOP

Sebelum memodelkan suhu udara dengan GOP, dilakukan pengujian Moran's I untuk memeriksa signifikansi dependensi spasial dari suhu maksimum dan suhu minimum antar 8 stamet. Langkah pertama yang dilakukan ialah membentuk matrik jarak antar 8 stamet, seperti yang ditunjukkan dalam Tabel 4.15.

Tabel 4.15 Matrik Jarak 8 Stasiun Meteorologi Jabotabek (dalam km)

Stamet	1	2	3	4	5	6	7	8
1	0	6,810	21,694	15,479	22,929	53,593	60,575	39,634
2	6,810	0	24,091	22,091	28,231	56,130	66,818	46,372
3	21,694	24,091	0	19,615	12,98	32,108	68,598	44,080
4	15,479	22,091	19,615	0	11,609	46,443	50,027	26,550
5	22,929	28,231	12,980	11,609	0	34,907	56,467	31,683
6	53,593	56,130	32,108	46,443	34,907	0	85,158	61,212
7	60,575	66,818	68,598	50,027	56,467	85,158	0	24,859
8	39,634	46,371	44,080	26,550	31,683	61,212	24,859	0

Ket.:

1 : Kemayoran

2 : Priok

3 : Cengkareng

4 : Pondok Betung

5 : Curug

6 : Tangerang

7 : Citeko

8 : Dermaga


Dari Tabel 4.15, dapat dikatakan bahwa stasiun yang terbelang terisolir dari stamet lainnya adalah stamet Citeko. Terlihat bahwa stamet terdekat dari Citeko ialah Dermaga yang terpisah sekitar 25 km. Untuk dapat menguji dependensi spasial, diperlukan matrik jarak terboboti yang hanya berisikan nilai 0 dan 1. Karena seluruh stamet tidak bersisian, maka diperlukan *cut-off distance* sebagai jarak maksimal yang masih memberikan pengaruh terhadap dinamika cuaca. Berdasarkan BMKG (2011) dan dengan asumsi elevasi (ketinggian) stamet yang seragam, digunakan *cut-off distance* sebesar 30 km.

Langkah berikutnya adalah menghitung Moran's I beserta p-value yang digunakan untuk melihat signifikansi dependensi spasial berdasarkan persamaan (2.38) dan (2.39) dan disajikan pada Tabel 4.16, berdasarkan matrik jarak terboboti yang distandarkan. Hal ini untuk memudahkan interpretasi terhadap Moran's I agar berada dalam range -1 hingga 1, seperti halnya korelasi Pearson.

Tabel 4.16 Signifikansi Moran's I pada Observasi Cuaca di 8 Stamet

Elemen cuaca	Moran's I	st.dev	p-value
T_{MAKS}	0,135	0,141	0,048
T_{MIN}	0,379	0,190	0,006

Berdasarkan Tabel 4.16, dapat disimpulkan bahwa dependensi spasial untuk kedua parameter cuaca, baik suhu maksimum dan suhu minimum, signifikan secara statistik pada tingkat signifikansi $\alpha=0,05$. Moran's I yang bernilai positif menyatakan bahwa suhu udara di lokasi yang berdekatan cenderung memiliki hubungan/asosiasi yang lebih tinggi ketimbang lokasi yang berjauhan. Diindikasikan bahwa kekuatan asosiasi spasial suhu minimum cenderung lebih tinggi daripada suhu maksimum, jika dilihat berdasarkan nilai Moran's I suhu minimum sebesar 0,379 yang lebih tinggi daripada suhu maksimum yang sebesar 0,135.



Gambar 4.11 Moran Scatterplot; (a) suhu maksimum; (b) suhu minimum

Gambar 4.11 mengindikasikan bahwa 5 dari 8 stasiun berada di kuadran 1, sementara 3 stamet lainnya, yaitu Citeko, Dermaga, Tangerang, berada di kuadran 2 dan 3 untuk suhu maksimum dan di kuadran 3 dan 4 untuk suhu minimum. Berdasarkan Cliff dan Ord (1981), 7 dari 8 stasiun memiliki dependensi spasial yang positif karena berada di kuadran 1 dan 3, dimana hanya satu stamet saja

yang cenderung memiliki dependensi spasial bernilai negatif, yaitu stamet Tangerang. Meskipun Citeko dan Dermaga dinyatakan memiliki hubungan spasial yang positif dan berada di kuadran yang sama, namun posisi keduanya di Gambar 4.11 yang relatif berjauhan merefleksikan bahwa kekuatan hubungan antara keduanya tidak cukup tinggi.

Setelah mengetahui bahwa suhu udara di 8 stamet terbukti secara statistik memiliki dependensi/asosiasi secara spasial, maka langkah berikutnya adalah menerapkan tahap pertama dalam pemodelan GOP, yaitu mendapatkan estimasi parameter β_0 dan β_1 untuk mengoreksi bias dan mendapatkan residual untuk membentuk semivariogram empiris. Untuk kasus ini, model regresi GOP yang berlaku adalah

$$y_{s,t} = \beta_0 + \beta_1 x_{s,t} + \varepsilon_{s,t}$$

dimana $x_{s,t}$ merupakan prakiraan NWP untuk suhu udara pada stamet s dan waktu/hari ke- t . Panjang training yang digunakan untuk model GOP adalah serupa dengan panjang training BMA pada sub-bab sebelumnya, yaitu 30 hari, meskipun terbilang pendek jika dibandingkan dengan Gel *et al.* (2004) yang menyarankan penggunaan periode training yang lebih panjang agar fenomena cuaca tertangkap dengan lebih baik dan representatif. Tabel 4.17 berikut merupakan estimasi parameter β_0 dan β_1 untuk model GOP dengan training 30 hari.


Tabel 4.17 Estimasi Parameter Regresi Model GOP, 1 Jan'09 – 30 Jan '09

Elemen cuaca	$\hat{\beta}_0$	$\hat{\beta}_1$	$SE(\hat{\beta}_0)$	$SE(\hat{\beta}_1)$
T _{MAKS}	1,785	0,959	3,053	0,106
T _{MIN}	25,963	-0,131	5,304	0,230

Tabel 4.17 mengindikasikan kontradiksi signifikansi parameter dimana β_0 T_{MAKS} tidak signifikan, tetapi β_1 T_{MAKS} signifikan jika dibandingkan terhadap SE masing-masing parameter. Namun, tidak demikian halnya dengan suhu minimum dimana justru β_0 T_{MIN} yang signifikan, sementara β_1 T_{MIN} tidak signifikan. Kendati terdapat salah satu parameter yang tidak signifikan, namun hasil estimasi ini selaras dengan Gel *et al.* (2004) yang juga mengalami hal serupa, tetapi tidak berdampak ke *coverage* dan lebar interval prediktif model GOP.

Tahap berikutnya adalah membentuk semivariogram empiris model eksponensial dengan parameter spasial ρ^2 , σ^2 dan r yang diestimasi berdasarkan

metode iteratif L-BFGS implementasi dari persamaan (4.18) hingga persamaan (4.25). Gambar 4.12 merupakan semivariogram yang dibentuk dari residual model GOP berdasarkan estimasi β_0 dan β_1 dari Tabel 4.17.



Gambar 4.12 Semivariogram Empiris Suhu Udara, 1 Jan '09 – 30 Jan '09
(kiri) suhu maksimum (kanan) suhu minimum

Nilai semivariogram pada Gambar 4.12 konstan setelah jarak r sebesar 8,69 km. Hal ini mengindikasikan bahwa suhu udara antar dua lokasi tidak memiliki dependensi pada jarak 8,69 km atau lebih, dengan nilai *sill* (*nugget* + *partial sill*) 3,65 untuk suhu maksimum dan 2,53 untuk suhu minimum. Berdasarkan Cressie (1993), *sill* yang makin besar dapat menyebabkan varians estimasi menjadi makin tinggi. Artinya, terdapat kemungkinan presisi prakiraan suhu maksimum lebih rendah daripada suhu minimum sehingga berdampak terhadap interval model GOP, dapat dievaluasi dari CRPS.

Gambar 4.12 mengindikasikan adanya inkonsistensi spasial yang terjadi pada kedua parameter cuaca. Pada jarak-jarak tertentu, terdapat beberapa *bin* atau kelompok stamet yang nilai semivariogram jauh lebih tinggi daripada kelompok lainnya. Karena sebagian besar pola ini terlihat pada *bin* dengan jarak di atas 50 km, muncul kemungkinan bahwa stamet Citeko, Tangerang dan Dermaga yang secara geografis lebih jauh ketimbang 5 stamet lainnya yang menyebabkan inkonsistensi spasial ini. Hal ini dikhawatirkan dapat mempengaruhi kebaikan model GOP karena semivariogram empiris pada Gel *et al.* (2004) dan Feldmann (2012) tidak menunjukkan pola yang inkonsisten seperti Gambar 4.12.

Kendati terdapat indikasi inkonsistensi spasial, namun proses simulasi yang dijalankan model GOP dengan memodifikasi residual untuk mendapatkan prakiraan cuaca terkalibrasi diharapkan dapat mengatasi fenomena tersebut. Untuk kasus ini, dilakukan simulasi hingga mendapatkan 99 realisasi anggota ensemble. Dari 99 realisasi tersebut, dipilih batas bawah dan batas atas yang dianggap dapat mewakili seluruh realisasi, yaitu persentil ke-5 (P_5) dan 95 (P_{95}).

Berdasarkan Gel *et al.* (2004), alasan penggunaan 99 realisasi adalah untuk mengakomodir nilai observasi bilamana GOP dikatakan terkalibrasi saat observasi suhu udara pada hari ke- t berada di antara kedua persentil tersebut, begitu pula sebaliknya. Kedua persentil tersebut berperan sebagai batas bawah dan batas atas dari interval prediktif 90%. Untuk mengetahui seberapa akurat dan reliabel prakiraan suhu udara, Tabel 4.18 menyajikan RMSE dan interval prediktif model GOP pada tanggal 31 Januari 2009. Prakiraan GOP untuk suhu udara di 8 stamet disajikan secara singkat pada Lampiran 51-52.

Tabel 4.18 RMSE Prakiraan GOP dan NWP untuk 8 Stamet, 31 Jan '09

Suhu Udara	Stamet	Obs. (°C)	NWP (°C)	GOP (°C)	P_5 (°C)	P_{95} (°C)	RMSE NWP	RMSE GOP
T_{MAKS}	Kemayoran	28,8	26,43	26,82	24,28	30,14	2,18°	2,12°
	Priok	28,7	26,55	26,48	23,73	30,52		
	Cengkareng	28,6	26,42	28,75	24,41	29,75		
	Pd. Betung	29,0	26,49	27,80	24,44	30,25		
	Curug	28,3	26,26	26,64	23,63	29,66		
	Tangerang	29,2	26,34	26,22	23,93	30,79		
	Citeko	25,0	26,77	28,73	24,60	31,34		
	Dermaga	27,8	26,73	27,60	24,41	31,00		
Suhu Udara	Stamet	Obs. (°C)	NWP (°C)	GOP (°C)	P_5 (°C)	P_{95} (°C)	RMSE NWP	RMSE GOP
T_{MIN}	Kemayoran	23,8	22,6	24,11	20,62	25,43	1,57°	2,29°
	Priok	23,8	23,18	23,62	20,39	24,59		
	Cengkareng	23,4	22,55	24,22	20,24	25,74		
	Pd. Betung	23,4	22,38	23,66	20,08	25,68		
	Curug	23,5	22,19	25,69	20,42	24,89		
	Tangerang	23,3	22,39	24,25	20,50	25,31		
	Citeko	18,4	22,08	23,68	20,59	25,35		
	Dermaga	22,4	22,24	25,11	20,72	25,52		

Dari Tabel 4.18, dapat dikatakan bahwa GOP sebenarnya mampu mengoreksi bias luaran NWP, seperti pada suhu maksimum, meskipun tingkat

koreksi bias sangat rendah, yaitu tidak lebih dari 5%. Namun untuk suhu minimum, akurasi prakiraan GOP sangat buruk yang bahkan memiliki RMSE jauh lebih tinggi daripada RMSE NWP. Salah satu penyebab lemahnya akurasi GOP adalah kegagalan GOP untuk meramalkan suhu udara di daerah Citeko dan Dermaga yang secara geografis lebih jauh daripada stamet lainnya. Hal ini diperparah dengan nilai observasi yang tidak masuk ke dalam interval prediktif 90% untuk stamet Citeko.


Kelemahan tersebut kemungkinan akibat dari inkonsistensi spasial yang terlihat dari semivariogram empiris pada Gambar 4.12. Artinya, GOP sensitif dengan inkonsistensi spasial yang dapat diakibatkan oleh kurangnya lokasi pengamatan, karakter data yang tidak tepat dianalisis dengan metode spasial, dan sebagainya. Oleh karena itu, dilakukan pemodelan ulang tanpa melibatkan stamet Citeko yang dimulai dari estimasi parameter β_0 dan β_1 untuk model GOP dengan periode training serupa, yaitu 30 hari, dan disajikan pada Tabel 4.19.

Tabel 4.19 Estimasi Parameter Regresi Model GOP tanpa Stamet Citeko, 1 Jan'09 – 30 Jan '09

Elemen cuaca	$\hat{\beta}_0$	$\hat{\beta}_1$	$SE(\hat{\beta}_0)$	$SE(\hat{\beta}_1)$
T _{MAKS}	4,739	0,884	1,73	0,06
T _{MIN}	21,894	0,074	3,44	0,15

Jika dibandingkan dengan Tabel 4.17 yang sama-sama menampilkan estimasi parameter regresi, dapat dikatakan bahwa dua parameter regresi untuk suhu maksimum pada Tabel 4.19 adalah signifikan pada α sebesar 0,05, tidak seperti sebelumnya dimana hanya *slope* atau β_1 saja yang signifikan. Hal ini dapat berdampak pada lebih akuratnya ramalan cuaca yang dihasilkan. Namun, tidak demikian halnya dengan suhu minimum dimana salah satu parameter tidak signifikan, yaitu β_1 . Ada kemungkinan hal ini menyebabkan persentase peningkatan akurasi prakiraan pada suhu minimum tidak sebaik suhu maksimum.

Kemudian membentuk semivariogram empiris model eksponensial dengan parameter spasial ρ^2 , σ^2 dan r yang diestimasi berdasarkan metode iteratif L-BFGS implementasi dari persamaan (4.18) hingga persamaan (4.25). Gambar 4.13 merupakan semivariogram yang dibentuk dari residual model GOP berdasarkan estimasi β_0 dan β_1 dari Tabel 4.19.



Gambar 4.13 Semivariogram Empiris Suhu Udara tanpa Citeko, 1 Jan '09 – 30 Jan '09 (kiri) suhu maksimum (kanan) suhu minimum

Berdasarkan Gambar 4.13, terlihat adanya penyesuaian semivariogram eksponensial yang cukup nyata jika dibandingkan dengan semivariogram pada Gambar 4.12 yang melibatkan stamet Citeko. Semivariogram hasil estimasi (teoritis) mampu untuk mengikuti pola spasial dari semivariogram empiris (titik noktah ○). Artinya, proses simulasi spasial kemungkinan besar makin mampu untuk memodifikasi residual data testing, sehingga diperoleh prakiraan suhu udara yang semakin akurat. Tabel 4.20 menyajikan perbandingan RMSE dan beberapa indikator lainnya yang lazim digunakan untuk mengevaluasi model GOP antara model yang melibatkan Citeko dan tanpa Citeko.


Tabel 4.20 Perbandingan Indikator Kebajikan Model GOP, 31 Jan '09-31 Des '10

	Dengan stamet Citeko			Tanpa stamet Citeko		
	RMSE (°C)	CRPS	Coverage (%)	RMSE (°C)	CRPS	Coverage (%)
T_{MAKS}	3,07	1,54	75,59	1,92	0,98	71,43
T_{MIN}	2,67	1,43	68,58	1,86	0,87	78,97

Berdasarkan Tabel 4.20, prakiraan suhu udara yang tidak melibatkan Citeko jauh lebih akurat (RMSE lebih rendah), lebih reliabel (CRPS lebih rendah), dan terkalibrasi dengan lebih tajam (*coverage* suhu minimum makin mendekati angka 90%). Dengan demikian, dapat dikatakan bahwa lokasi penelitian yang jauh terisolir daripada lokasi-lokasi lainnya dapat memberikan dampak yang cukup signifikan terhadap akurasi dan presisi prakiraan cuaca model GOP. Selain itu, Citeko jauh memiliki karakteristik geografis yang berbeda karena berada di daerah dengan elevasi yang lebih tinggi daripada stamet lainnya.

4.3.7. Evaluasi Prakiraan BMA dan GOP

Setelah mengetahui kebaikan prakiraan yang dihasilkan kedua metode, langkah selanjutnya ialah membandingkan kebaikan prakiraan kedua metode tersebut. Namun sebelumnya, ramalan yang dihasilkan BMA dan GOP akan ditampilkan secara visual untuk melihat seberapa baik kedua metode menangkap pola cuaca yang terjadi di stamet tertentu, misalnya stamet Dermaga. Gambar 4.14 adalah prakiraan cuaca BMA dan GOP (melibatkan stamet Citeko), serta nilai observasi suhu maksimum dan suhu minimum pada stamet Dermaga selama 30 hari pertama periode testing, yaitu 31 Januari 2009 hingga 1 Maret 2009.



Gambar 4.14 Prakiraan BMA, GOP dan Observasi Suhu Udara Stamet Dermaga
(a) suhu maksimum (b) suhu minimum

Berdasarkan Gambar 4.14, diindikasikan bahwa BMA dan GOP mampu untuk mengikuti pola dan tren suhu maksimum, meskipun dari sisi akurasi BMA kemungkinan besar lebih tinggi ketimbang GOP. Pada sebagian besar hari pengamatan, prakiraan BMA lebih mendekati observasi. Namun demikian, kedua metode ini belum cukup akurat dalam melakukan prakiraan suhu minimum di Stamet Dermaga. Kedua metode ini masih belum mampu menangkap pola suhu minimum yang terbentuk karena pergerakannya yang lebih dinamis jika dibandingkan dengan pola suhu maksimum. Untuk memperkuat analisis deskripsi, maka perlu dilakukan perbandingan menggunakan indikator yang lebih objektif.

Agar BMA dan GOP dapat secara langsung dibandingkan, maka Feldmann (2012) menyarankan agregasi RMSE dan CRPS dari seluruh stamet untuk BMA. Tabel 4.21 menyajikan beberapa indikator kebaikan prakiraan NWP, BMA dan GOP dari seluruh 8 stamet yang dirata-rata, menggunakan panjang training selama 30 hari. Sementara, Lampiran 53 dan Lampiran 54 masing-masing menyajikan kriteria prakiraan yang sudah dicapai oleh BMA dan GOP berdasarkan BMKG (2011) dan nilai RMSE, CRPS dan *coverage* untuk tiap stamet.

Tabel 4.21 Evaluasi Prakiraan NWP, *Raw Ensemble* dan BMA untuk 8 Stamet

Indikator	Prakiraan	T _{MAKS}	T _{MIN}
RMSE (°C)	NWP	2,745	2,01
	<i>Mean ensemble</i>	1,058	0,805
	BMA	1,053	0,819
	GOP	3,07	2,67
CRPS	<i>Raw ensemble</i>	0,726	0,577
	BMA	0,576	0,451
	GOP	1,54	1,43

Berdasarkan Tabel 4.21, suhu maksimum lebih akurat jika diramalkan dengan BMA, sementara suhu minimum lebih akurat dengan menggunakan *mean ensemble* (rata-rata dari prakiraan PLS, PCR dan Ridge). Selain itu, BMA juga mampu mengkalibrasi ramalan dengan lebih reliabel ketimbang GOP. Hal ini terlihat dari CRPS BMA yang lebih rendah daripada CRPS *raw ensemble*, sementara CRPS GOP justru lebih tinggi daripada CRPS *raw ensemble*. Jadi, pada kasus ini, BMA mampu menghasilkan prakiraan cuaca yang lebih akurat dan reliabel ketimbang GOP.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan analisis yang telah dilakukan dan dibahas sebelumnya pada Bab 4, diperoleh kesimpulan sebagai berikut.

1. Pada model BMA, penaksiran parameter regresi $\beta_{0,m}$ dan $\beta_{1,m}$ untuk masing-masing anggota ensemble m dilakukan dengan metode *Maximum Likelihood Estimation* (MLE) distribusi normal. Penaksiran pembobot w_m dan varians σ^2 tidak dapat diselesaikan secara analitik menggunakan MLE, sehingga digunakan pendekatan iteratif *Expectation-Maximization* (EM) untuk mencari solusinya. Berikut ini adalah ringkasan persamaan bobot dan varians yang digunakan untuk mengkalibrasi prakiraan anggota ensemble dengan BMA.

$$w_m^{(i)} = \frac{1}{T} \sum_{t=1}^T z_{mt}^{(i)}, m = 1, 2, \dots, M$$

$$\sigma^{2(i)} = \frac{\sum_{t=1}^T \sum_{m=1}^M z_{mt}^{(i)} (y_t - f_{mt})^2}{T}$$

2. Pada model GOP, parameter spasial ρ^2 , σ^2 , dan r yang digunakan untuk memodifikasi residual guna mendapatkan prakiraan cuaca tidak dapat diestimasi secara analitik akibat derivatif fungsi objektif

$$g(\rho^2, \sigma^2, r) = \sum_{l=1}^k n_l \left(\frac{\hat{\gamma}(d_l)}{\rho^2 + \sigma^2 (1 - e^{-d_l/r})} - 1 \right)^2$$

yang tidak *close-form* sehingga

diperlukan pendekatan iteratif *Limited-Memory BFGS* (L-BFGS).

3. Untuk periode training selama 30 hari, prakiraan suhu udara di 8 stamet termasuk ke dalam kriteria baik-sedang, meskipun akurasi prakiraan BMA tidak berbeda nyata daripada prakiraan anggota ensemble, yaitu PLS, PCR, dan Ridge. Namun, dari aspek presisi, CRPS BMA lebih rendah daripada CRPS *raw ensemble* yang mengindikasikan bahwa persentase observasi suhu udara berada di interval prediktif BMA lebih tinggi. Selain itu, BMA juga mampu mengkalibrasi prakiraan cuaca dimana *coverage* yang dihasilkan

sudah mendekati standar 50%. Sementara, GOP menghasilkan ramalan yang masih memiliki bias cukup tinggi, bahkan RMSE GOP masih lebih tinggi daripada RMSE NWP. Namun, jika pemodelan GOP tidak melibatkan stamet Citeko, maka akurasi dan presisi ramalan meningkat hampir 2 kali lipat. Jika dibandingkan, dapat disimpulkan bahwa akurasi dan presisi prakiraan BMA lebih tinggi daripada GOP.

5.2 Saran

Berikut ini adalah saran yang dapat diberikan kepada BMKG sebagai otoritas terkait dan untuk penelitian selanjutnya, berdasarkan hasil analisis yang telah dilakukan pada penelitian ini.

1. Idealnya, BMA diolah menggunakan luaran NWP dari beragam sumber sehingga tidak lagi memerlukan *pre-processing* hingga regresi untuk mendapatkan prakiraan anggota ensemble. Hal tersebut sebenarnya tidak lazim dilakukan, sehingga muncul dugaan bahwa akurasi BMA yang tidak lebih baik daripada akurasi anggota ensemble salah satunya diakibatkan oleh faktor tersebut.
2. Untuk BMA, diperlukan simulasi secara komputasi intensif untuk mengetahui periode training mana yang menghasilkan RMSE dan CRPS lebih rendah.
3. Karena akurasi prakiraan GOP untuk suhu minimum masih cukup rendah, maka prediktor untuk penelitian selanjutnya dapat diganti dengan luaran NWP untuk tekanan udara, kelembapan, dan sebagainya.
4. GOP sebaiknya dilakukan dengan melibatkan stasiun meteorologi yang jauh lebih banyak, minimal puluhan stasiun dalam lingkup lokasi yang cukup berdekatan. Hal ini untuk meminimalkan potensi prakiraan yang kurang akurat akibat adanya satu atau beberapa stasiun yang posisinya secara geografis lebih jauh ketimbang sekumpulan stasiun lainnya.
5. Untuk penelitian GOP selanjutnya, dapat menerapkan validasi dan *windowing* sehingga model yang digunakan tidak konstan/statis dan selalu adaptif mengikuti karakteristik cuaca.
6. Untuk meningkatkan akurasi dan kalibrasi prakiraan cuaca, dimungkinkan untuk dilanjutkan dengan metode BMA spasial.

DAFTAR PUSTAKA

- Anggraeni, D. 2013. "Kalibrasi Peramalan *Ensemble* Data Curah Hujan Dengan Metode *Ensemble Model Output Statistics* (EMOS) dan *Bayesian Model Averaging* (BMA)". *Tesis*. Insitut Teknologi Sepuluh Nopember, Surabaya.
- Anselin, L. 1988. *Spatial Econometrics: Methods and Models*. Dordrecht: Kluwer Academic Publisher.
- Arfianto, A. D. 2008. "Aplikasi Model Regresi Logistik untuk Perkiraan Kejadian Hujan". *Skripsi*. Institut Pertanian Bogor.
- Berrocal, V.J, Raftery, A.E., dan Gneiting, T. 2007. Combining Spatial Statistical and Ensemble Information in Probabilistic Weather Forecast. *Monthly Weather Review AMS*, Vol. 135, pp.1386-1402.
- BMKG. 2011. *Kajian dan Aplikasi Model CCAM (Conformal Cubic Atmospheric Model) untuk Prakiraan Cuaca Jangka Pendek Menggunakan MOS (Model Output Statistics)*. Jakarta : Pusat Penelitian dan Pengembangan BMKG.
- Casella, G. dan Berger, R.L. 2002. *Statistical Inference Second Edition*. California: Brooks Cole.
- Cliff, A.D. dan Ord, J.K. 1981. *Spatial Processes: Models & Applications*. London: Pion Limited.
- Cressie, N.A.C. 1985. Fitting Variogram Models by Weighted Least Squares. *Mathematical Geology*, Vol. 17, No. 5, pp. 563–585.
- Cressie, N.A.C. 1993. *Statistics for Spatial Data Revised Edition*. New Jersey: John Wiley and Sons, Inc.
- Demeritt, D., Cloke, H., Pappenberger, F., Thielen, J., Bartholmes, J., dan Ramos, M-H. 2007. Ensemble predictions and perceptions of risk, uncertainty, and error in flood forecasting. *Environmental Hazards*, Vol.7, pp.115-127.

- Dempster, A.P., Laird, N.M., dan Rubin, D.B. 1977. Maximum Likelihood from Incomplete Data via the EM Algorithm. *Journal of the Royal Statistical Society*, Vol. 39, No. 1, pp. 1-38.
- Devin, K., Clarke, L., Roulston, M., Ziehmann, C., Brocker, J. dan Smith, L. 2004. *Generalising Model Output Statistics for Full Ensemble Forecasts*. Pembroke College Article. Oxford, United Kingdom.
- Draper, N.R. dan Smith, H. 1992. *Applied Regression Analysis Second Edition*. New York: John Wiley and Sons, Inc.
- Feldmann, K. 2012. "Statistical Postprocessing of Ensemble Forecasts for Temperature: The Importance of Spatial Modeling". *Tesis Diplomarbeit*. Ruperto-Carola University of Heidelberg, Germany.
- Feldmann, K., Scheuerer, M. dan Thorarinsdottir, T. L. 2015. Spatial Postprocessing of Ensemble Forecasts for Temperature Using Nonhomogeneous Gaussian Regression. *American Meteorological Society*, Vol. 143, pp. 955-971.
- Gel, Y., Raftery, A.E., dan Gneiting, T. 2004. Calibrated probabilistic mesoscale weather field forecasting: The Geostatistical Output Perturbation (GOP) method (with discussion). *Journal of the American Statistical Association*, Vol. 99 (467), pp. 575–583.
- Gneiting, T., Raftery, A.E, Westveld III, A.H., dan Goldman, T. 2005. Calibrated Probabilistic Forecasting Using Ensemble Model Output Statistics and Minimum CRPS Estimation. *Monthly Weather Review AMS*, Vol. 133, pp. 1098-1118.
- Hammill, T.M. 2001. Interpretation of Rank Histograms for Verifying Ensemble Forecasts. *Monthly Weather Review AMS*, Vol. 129, pp. 550-560.
- Idowu, O.S. dan Rautenbach, C.J. de W. 2009. *Model Output Statistics to Improve Severe Storm Prediction Over Western Sahel*. South Africa: Department of Geography, Geoinformatics and Meteorology, University of Pretoria.
- Johnson, R.A. dan Wichern, D.W. 2007. *Applied Multivariate Statistical Analysis 5th Edition*. New Jersey: Prentice Hall.
- Jolliffe, I.T. 2002. *Principal Component Analysis, Second Edition*. New York: Springer-Verlag.

- Jolliffe, I.T. dan Stephenson, D.B. 2011. *Forecast Verification: A Practitioner's Guide in Atmospheric Science, 2nd Edition*. Hoboken: Wiley.
- Kuswanto, H. dan Sari, M.R. 2013. Bayesian Model Averaging With Markov Chain Monte Carlo For Calibrating Temperature Forecast From Combination of Time Series Models. *Journal of Mathematics and Statistics*, Vol. 9(4), pp. 349-356.
- Lange, K. 2010. *Numerical Analysis for Statisticians, Second Edition*. New York: Springer-Verlag.
- Linacre, E. dan Geerts, B. 2003. *Climate and Weather Explained*. New York : Routledge.
- Liu, D.C. dan Nocedal, J. 1989. On The Limited Memory BFGS Method for Large Scale Optimization. *Mathematical Programming*, Vol. 45, pp. 503-528
- McLachlan, G.J dan Krishnan, T. 2008. *The EM Algorithm and Extensions, Second Edition*. New Jersey: John Wiley & Sons, Inc.
- Möller, A. 2014. "Multivariate and spatial ensemble postprocessing methods". *Disertasi*. Ruperto-Carola University of Heidelberg, Germany.
- [NOAA] National Oceanic and Atmospheric Administration's. 2015. *Glossary*. Diakses dari laman *National Weather Service (NWS)* Amerika Serikat: <http://w1.weather.gov/glossary/> pada 19 Februari 2015.
- Park, Y.Y. 2006. Recent development of ensemble forecast system. ASEAN-ROK Cooperation Training Workshop for the Use of Numerical Weather Prediction Products, KMA, Seoul, South Korea, pp. 93-177.
- Quinn, T.J. 1990. *Temperature :Second Edition*. Massachusetts: Academic Press
- Raftery, A.E., Gneiting, T., Balabdaoui, F. dan Polakowski, M. 2005. Using Bayesian Model Averaging to Calibrate Forecast Ensembles. *Monthly Weather Review AMS*, Vol. 133, pp.1155-1174.
- Raftery, A.E. dan Zheng, Y. 2003. Discussion: Performance of Bayesian Model Averaging. *Journal of the American Statistical Association*, Vol. 98, pp. 931-938.

- Raible, C.C., Bischof, G., dan Fraedrich, K. 1998. *Statistical Single-Station Short-Term Forecasting of Temperature and Probability of Precipitation: Area Interpolation and NWP Combination*. Jerman : Hamburg University.
- Rencher, A.C. dan Schaalje, G.B. 2008. *Linear Models in Statistics Second Edition*. New Jersey: John Wiley and Sons, Inc.
- Sari, I.G.A.M.K.K. 2013. “Pendekatan Regresi Partial Least Square Univariate dan Multivariate Response untuk Memprediksi Suhu dan Kelembapan”. *Tesis*. Surabaya : Institut Teknologi Sepuluh Nopember.
- Schmeits, M.J. dan Kok, K.J. 2010. A Comparison between Raw Ensemble Output, (Modified) Bayesian Model Averaging and Extended Logistic Regression Using ECMWF Ensemble Precipitation Forecast. *Monthly Weather Review AMS*, Vol. 138, pp. 4199-4211.
- Tanudidjaja. 1993. *Ilmu Pengetahuan Bumi dan Antariksa*. Jakarta: Penerbit Departemen Pendidikan dan Kebudayaan.
- Tjasyono, B.H.K. dan Harijono, S.W.B. 2008. *Model Meteorologi Indonesia 2 Awan dan Hujan Monsun*. Badan Meteorologi dan Geofisika Jakarta.
- Viney, N.R., Croke, B.E.W., Breuer, L., Bormann, H., Bronstert, A., Freed, H., Graff, T., Hubrechts, L., Huisman, J.A., Jakeman, A.J., Kite, G.W., Lanini, J., Leavesley, G., Lettenmaier, D.P., Lindstrom, G., Seibert, J., Sivapalan, M., dan Willem, P. 2005. Ensemble modeling of the hydrological impacts of land use change. *German Science Foundation & Collaborative Research Center*, pp. 2967- 2973.
- Vrugt, J.A., Diks, C.G.H., dan Clark, M.P. 2008. Ensemble Bayesian Model Averaging Using Markov Chain Monte Carlo Sampling. *Environmental Fluid Mechanics*, Vol. 226.
- Wilks, D.S. 2006. *Statistical Methods in the Atmospheric Sciences 2nd Edition*. Boston: Elsevier.
- Wold, S., Sjöström, M., dan Eriksson, L. 2001. PLS-regression: a basic tool of chemometrics. *Chemometrics and Intelligent Laboratory Systems*, Vol. 58, pp. 109-130.

LAMPIRAN

Lampiran 1. Rata-rata dan Standar Deviasi Variabel Respon

Var. Respon	Stamet	Rata-rata (°C)	Standar Deviasi
T _{MAKS} (°C)	Kemayoran	32,42	1,56
	Priok	32,22	1,45
	Cengkareng	31,99	1,46
	Pondok Betung	33,15	1,62
	Curug	32,21	1,61
	Tangerang	32,62	1,53
	Citeko	26,1	1,55
	Dermaga	31,68	1,55
T _{MIN} (°C)	Kemayoran	25,42	0,96
	Priok	25,83	0,99
	Cengkareng	24,14	0,84
	Pondok Betung	24,19	0,99
	Curug	23,37	0,89
	Tangerang	23,95	1,20
	Citeko	18,65	0,83
	Dermaga	22,76	0,92

Lampiran 2. Rata-rata dan Standar Deviasi Parameter NWP Stamet Kemayoran

Variabel (grid)	Rata-Rata	Std. Deviasi	Variabel (grid)	Rata-Rata	Std. Deviasi
dpsdt (1)	-10,36	140,47	rnd (1)	4,98	12,31
dpsdt (2)	-10,59	140,35	rnd (2)	4,20	10,79
dpsdt (3)	-10,81	140,15	rnd (3)	4,69	10,80
dpsdt (4)	-9,96	139,76	rnd (4)	4,47	10,90
dpsdt (5)	-10,27	139,64	rnd (5)	4,73	11,25
dpsdt (6)	-10,48	139,47	rnd (6)	4,64	10,62
dpsdt (7)	-9,46	138,88	rnd (7)	3,48	8,61
dpsdt (8)	-9,71	138,73	rnd (8)	3,52	9,07
dpsdt (9)	-9,96	138,61	rnd (9)	3,60	9,01
⋮	⋮	⋮	⋮	⋮	⋮
rh4 (1)	79,29	8,25	zg4 (1)	928,27	2,15
rh4 (2)	79,40	8,06	zg4 (2)	924,09	2,06
rh4 (3)	79,39	7,72	zg4 (3)	924,56	2,13
rh4 (4)	78,31	8,20	zg4 (4)	943,20	2,30
rh4 (5)	78,44	8,01	zg4 (5)	934,48	2,18
rh4 (6)	78,57	7,75	zg4 (6)	937,21	2,20
rh4 (7)	77,56	8,30	zg4 (7)	967,25	2,31
rh4 (8)	77,69	8,12	zg4 (8)	959,45	2,29
rh4 (9)	77,86	7,91	zg4 (9)	960,53	2,21

Lampiran 3. Rata-rata dan Standar Deviasi Parameter NWP Stamet Priok

Variabel (grid)	Rata-Rata	Std. Deviasi	Variabel (grid)	Rata-Rata	Std. Deviasi
dpsdt (1)	-10,56	141,03	rnd (1)	4,13	11,37
dpsdt (2)	-10,63	140,85	rnd (2)	2,16	9,08
dpsdt (3)	-10,86	140,63	rnd (3)	2,44	8,37
dpsdt (4)	-10,36	140,47	rnd (4)	4,98	12,31
dpsdt (5)	-10,59	140,35	rnd (5)	4,20	10,79
dpsdt (6)	-10,81	140,15	rnd (6)	4,69	10,80
dpsdt (7)	-9,96	139,76	rnd (7)	4,47	10,90
dpsdt (8)	-10,27	139,64	rnd (8)	4,73	11,25
dpsdt (9)	-10,48	139,47	rnd (9)	4,64	10,62
⋮	⋮	⋮	⋮	⋮	⋮
rh4 (1)	80,34	8,25	zg4 (1)	924,15	2,11
rh4 (2)	80,49	8,19	zg4 (2)	924,01	2,09
rh4 (3)	80,47	7,92	zg4 (3)	924,04	2,07
rh4 (4)	79,30	8,25	zg4 (4)	928,26	2,15
rh4 (5)	79,41	8,06	zg4 (5)	924,08	2,06
rh4 (6)	79,41	7,73	zg4 (6)	924,55	2,12
rh4 (7)	78,32	8,20	zg4 (7)	943,20	2,29
rh4 (8)	78,45	8,01	zg4 (8)	934,47	2,17
rh4 (9)	78,59	7,75	zg4 (9)	937,20	2,19

Lampiran 4. Rata-rata dan Standar Deviasi Parameter NWP Stamet Cengkareng

Variabel (grid)	Rata-Rata	Std. Deviasi	Variabel (grid)	Rata-Rata	Std. Deviasi
dpsdt (1)	-10,86	140,63	rnd (1)	2,44	8,37
dpsdt (2)	-11,16	140,49	rnd (2)	3,21	8,43
dpsdt (3)	-11,49	140,38	rnd (3)	3,99	8,88
dpsdt (4)	-10,81	140,15	rnd (4)	4,69	10,80
dpsdt (5)	-11,08	139,94	rnd (5)	5,46	11,75
dpsdt (6)	-11,35	139,78	rnd (6)	5,79	12,05
dpsdt (7)	-10,48	139,47	rnd (7)	4,64	10,62
dpsdt (8)	-10,69	139,28	rnd (8)	4,63	10,31
⋮	⋮	⋮	⋮	⋮	⋮
rh4 (2)	80,46	7,75	zg4 (2)	924,35	2,11
rh4 (3)	80,41	7,62	zg4 (3)	925,84	2,13
rh4 (4)	79,39	7,72	zg4 (4)	924,56	2,13
rh4 (5)	79,38	7,47	zg4 (5)	928,83	2,17
rh4 (6)	79,38	7,34	zg4 (6)	934,84	2,22
rh4 (7)	78,57	7,75	zg4 (7)	937,21	2,20
rh4 (8)	78,68	7,53	zg4 (8)	944,38	2,18
rh4 (9)	78,78	7,39	zg4 (9)	953,55	2,28

Lampiran 5. Rata-rata dan Standar Deviasi Parameter NWP Stamet Pondok Betung

Variabel (grid)	Rata-Rata	Std. Deviasi	Variabel (grid)	Rata-Rata	Std. Deviasi
dpsdt (1)	-10,27	139,64	rnd (1)	4,73	11,25
dpsdt (2)	-10,48	139,47	rnd (2)	4,64	10,62
dpsdt (3)	-10,69	139,28	rnd (3)	4,63	10,31
dpsdt (4)	-9,71	138,73	rnd (4)	3,52	9,07
dpsdt (5)	-9,96	138,61	rnd (5)	3,60	9,01
dpsdt (6)	-10,20	138,51	rnd (6)	3,76	9,09
dpsdt (7)	-9,15	137,85	rnd (7)	3,24	7,94
dpsdt (8)	-9,45	137,75	rnd (8)	3,35	8,22
dpsdt (9)	-9,71	137,65	rnd (9)	3,50	8,51
⋮	⋮	⋮	⋮	⋮	⋮
rh4 (1)	78,44	8,01	zg4 (1)	934,48	2,18
rh4 (2)	78,57	7,75	zg4 (2)	937,21	2,20
rh4 (3)	78,68	7,53	zg4 (3)	944,38	2,18
rh4 (4)	77,69	8,12	zg4 (4)	959,45	2,29
rh4 (5)	77,86	7,91	zg4 (5)	960,53	2,21
rh4 (6)	78,09	7,69	zg4 (6)	964,25	2,19
rh4 (7)	77,01	8,37	zg4 (7)	992,32	2,28
rh4 (8)	77,18	8,14	zg4 (8)	989,21	2,22
rh4 (9)	77,54	7,88	zg4 (9)	990,40	2,34

Lampiran 6. Rata-rata dan Standar Deviasi Parameter NWP Stamet Curug

Variabel (grid)	Rata-Rata	Std. Deviasi	Variabel (grid)	Rata-Rata	Std. Deviasi
dpsdt (1)	-10,92	139,07	rnd (1)	4,50	10,02
dpsdt (2)	-11,14	138,83	rnd (2)	4,19	9,69
dpsdt (3)	-11,37	138,60	rnd (3)	4,04	9,58
dpsdt (4)	-10,41	138,38	rnd (4)	3,98	9,15
dpsdt (5)	-10,54	138,00	rnd (5)	3,96	9,08
dpsdt (6)	-10,78	137,71	rnd (6)	4,01	9,48
dpsdt (7)	-9,87	137,37	rnd (7)	3,60	8,43
dpsdt (8)	-10,16	137,14	rnd (8)	3,79	8,89
⋮	⋮	⋮	⋮	⋮	⋮
rh4 (2)	78,87	7,27	zg4 (2)	964,07	2,18
rh4 (3)	78,92	7,22	zg4 (3)	973,72	2,41
rh4 (4)	78,40	7,51	zg4 (4)	970,16	2,16
rh4 (5)	78,48	7,34	zg4 (5)	990,25	2,65
rh4 (6)	78,46	7,27	zg4 (6)	1001,79	2,30
rh4 (7)	77,95	7,65	zg4 (7)	1015,05	4,06
rh4 (8)	78,08	7,54	zg4 (8)	1026,30	2,20
rh4 (9)	78,09	7,58	zg4 (9)	1012,36	3,42

Lampiran 7. Rata-rata dan Standar Deviasi Parameter NWP Stamet Tangerang

Variabel (grid)	Rata-Rata	Std. Deviasi	Variabel (grid)	Rata-Rata	Std. Deviasi
dpsdt (1)	-10,81	140,15	rnd (1)	4,69	10,80
dpsdt (2)	-11,08	139,94	rnd (2)	5,46	11,75
dpsdt (3)	-11,35	139,78	rnd (3)	5,79	12,05
dpsdt (4)	-10,48	139,47	rnd (4)	4,64	10,62
dpsdt (5)	-10,69	139,28	rnd (5)	4,63	10,31
dpsdt (6)	-10,92	139,07	rnd (6)	4,50	10,02
dpsdt (7)	-9,96	138,61	rnd (7)	3,60	9,01
dpsdt (8)	-10,20	138,51	rnd (8)	3,76	9,09
dpsdt (9)	-10,41	138,38	rnd (9)	3,98	9,15
⋮	⋮	⋮	⋮	⋮	⋮
rh4 (1)	79,39	7,72	zg4 (1)	924,56	2,13
rh4 (2)	79,38	7,47	zg4 (2)	928,83	2,17
rh4 (3)	79,38	7,34	zg4 (3)	934,84	2,22
rh4 (4)	78,57	7,75	zg4 (4)	937,21	2,20
rh4 (5)	78,68	7,53	zg4 (5)	944,38	2,18
rh4 (6)	78,78	7,39	zg4 (6)	953,55	2,28
rh4 (7)	77,86	7,91	zg4 (7)	960,53	2,21
rh4 (8)	78,09	7,69	zg4 (8)	964,25	2,19
rh4 (9)	78,40	7,51	zg4 (9)	970,16	2,16

Lampiran 8. Rata-rata dan Standar Deviasi Parameter NWP Stamet Citeko

Variabel (grid)	Rata-Rata	Std. Deviasi	Variabel (grid)	Rata-Rata	Std. Deviasi
dpsdt (1)	-8,93	137,97	rnd (1)	3,23	7,90
dpsdt (2)	-9,15	137,85	rnd (2)	3,24	7,94
dpsdt (3)	-9,45	137,75	rnd (3)	3,35	8,22
dpsdt (4)	-8,42	137,13	rnd (4)	3,10	7,53
dpsdt (5)	-8,94	137,16	rnd (5)	3,30	7,85
dpsdt (6)	-9,30	137,24	rnd (6)	3,36	8,04
dpsdt (7)	-7,65	135,06	rnd (7)	2,95	7,00
dpsdt (8)	-8,23	135,67	rnd (8)	3,64	8,06
⋮	⋮	⋮	⋮	⋮	⋮
rh4 (2)	77,01	8,37	zg4 (2)	992,32	2,28
rh4 (3)	77,18	8,14	zg4 (3)	989,21	2,22
rh4 (4)	76,63	9,06	zg4 (4)	1046,32	3,77
rh4 (5)	76,64	8,81	zg4 (5)	1025,18	2,72
rh4 (6)	76,88	8,43	zg4 (6)	1001,66	3,80
rh4 (7)	76,04	9,93	zg4 (7)	1219,20	2,90
rh4 (8)	75,98	9,81	zg4 (8)	1127,18	3,81
rh4 (9)	76,51	9,54	zg4 (9)	1035,18	2,83

Lampiran 9. Rata-rata dan Standar Deviasi Parameter NWP Stamet Dermaga

Variabel (grid)	Rata-Rata	Std. Deviasi	Variabel (grid)	Rata-Rata	Std. Deviasi
dpsdt (1)	-8,94	137,16	rnd (1)	3,30	7,85
dpsdt (2)	-9,30	137,24	rnd (2)	3,36	8,04
dpsdt (3)	-9,30	136,97	rnd (3)	3,08	7,69
dpsdt (4)	-8,23	135,67	rnd (4)	3,64	8,06
dpsdt (5)	-8,29	136,35	rnd (5)	4,11	8,77
dpsdt (6)	-7,61	136,11	rnd (6)	3,98	8,88
dpsdt (7)	-6,98	132,59	rnd (7)	3,87	8,69
dpsdt (8)	-6,70	134,04	rnd (8)	4,44	9,69
dpsdt (9)	-5,88	133,20	rnd (9)	4,18	9,52
⋮	⋮	⋮	⋮	⋮	⋮
rh4 (1)	76,64	8,81	zg4 (1)	1025,18	2,72
rh4 (2)	76,88	8,43	zg4 (2)	1001,66	3,80
rh4 (3)	77,29	8,08	zg4 (3)	1015,53	2,47
rh4 (4)	75,98	9,81	zg4 (4)	1127,18	3,81
rh4 (5)	76,51	9,54	zg4 (5)	1035,18	2,83
rh4 (6)	77,37	9,27	zg4 (6)	1044,13	2,33
rh4 (7)	74,36	11,29	zg4 (7)	1358,85	9,39
rh4 (8)	75,18	10,83	zg4 (8)	1192,46	22,01
rh4 (9)	75,97	10,44	zg4 (9)	1271,13	2,49

Lampiran 10. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Kemayoran

Variabel	Byk. PC	Nilai Eigen	Kum. Varians	Variabel	Byk. PC	Nilai Eigen	Kum. Varians
dpsdt	1	8,999	99,98%	temp1	1	8,619	95,76%
mixr1	1	8,234	91,49%	temp2	1	8,726	96,96%
mixr2	1	8,67	96,34%	temp4	1	8,91	99%
mixr4	1	8,753	97,25%	tmaxscr	1	8,754	97,26%
omega1	1	8,863	98,48%	tminscr	1	8,315	92,39%
omega2	1	8,291	92,12%	tpan	1	8,617	95,75%
omega4	1	8,083	89,82%	tscrn	1	8,613	95,70%
pblh	1	8,197	91,08%	u1	1	8,758	97,31%
ps	1	8,997	99,97%	u2	1	8,839	98,21%
psl	1	8,998	99,98%	u4	1	8,945	99,39%
qgscrn	1	8,233	91,48%	ustar	1	8,182	90,91%
rh1	1	7,984	88,71%	v1	1	8,309	92,32%
rh2	1	8,593	95,48%	v2	1	8,33	92,55%
rh4	1	8,736	97,07%	v4	1	8,841	98,24%
rnd	1	7,682	85,36%	zg1	3	3,882; 2,05;1,061	77,71%

Lampiran 10. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Kemayoran (lanjutan)

Variabel	Byk. PC	Nilai Eigen	Kum. Varians	Variabel	Byk. PC	Nilai Eigen	Kum. Varians
zg2	2	6,58;1,254	87,06%	zg4	1	8,74	97,12%

Lampiran 11. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Priok

Variabel	Byk. PC	Nilai Eigen	Kum. Varians	Variabel	Byk. PC	Nilai Eigen	Kum. Varians
dpsdt	1	8,999	99,98%	temp2	1	8,543	94,92%
mixr1	1	7,681	85,34%	temp4	1	8,899	98,87%
mixr2	1	8,568	95,2%	tmaxscr	1	8,093	89,92%
mixr4	1	8,715	96,84%	tminscr	1	7,529	83,66%
omega1	1	8,746	97,18%	tpan	2	7,625;1,117	97,13%
omega2	1	7,840	87,11%	tscrn	1	7,984	88,72%
omega4	1	7,771	86,34%	u1	1	8,614	95,71%
pblh	2	7,052;1,451	94,48%	u2	1	8,822	98,02%
ps	1	8,997	99,97%	u4	1	8,948	99,42%
psl	1	8,998	99,98%	ustar	1	7,878	87,53%
qgscrn	1	7,744	86,04%	v1	1	7,907	87,86%
rh1	2	6,822;1,601	93,59%	v2	1	8,330	92,56%
rh2	1	8,420	93,55%	v4	1	8,865	98,5%
rh4	1	8,692	96,57%	zg1	4	2,975;2,625 1,253;1,017	87,44%
rnd	2	7,085;1,213	92,2%	zg2	1	6,672	74,14%
temp1	1	7,772	86,36%	zg4	1	8,752	97,25%

Lampiran 12. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Cengkareng

Variabel	Byk. PC	Nilai Eigen	Kum. Varians	Variabel	Byk. PC	Nilai Eigen	Kum. Varians
dpsdt	1	8,999	99,98%	rh2	1	8,451	93,9%
mixr1	1	7,775	86,39%	rh4	1	8,687	96,52%
mixr2	1	8,577	95,3%	rnd	1	7,350	81,66%
mixr4	1	8,718	96,86%	temp1	1	7,946	88,29%
omega1	1	8,854	98,37%	temp2	1	8,609	95,65%
omega2	1	8,159	90,66%	temp4	1	8,903	98,92%
omega4	1	7,880	87,56%	tmaxscr	1	8,206	91,18%
pblh	2	7,147;1,378	94,73%	tminscr	1	7,814	86,83%
ps	1	8,998	99,98%	tpan	2	7,764;1,092	98,4%
psl	1	8,998	99,98%	tscrn	1	7,970	88,55%
qgscrn	1	7,749	86,1%	u1	1	8,582	95,35%
rh1	2	7,018;1,434	93,91%	u2	1	8,822	98,03%

Lampiran 12. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Cengkareng (lanjutan)

Variabel	Byk. PC	Nilai Eigen	Kum. Varians	Variabel	Byk. PC	Nilai Eigen	Kum. Varians
u4	1	8,949	99,44%	v4	1	8,874	98,6%
ustar	1	7,955	88,39%	zg1	3	3,084; 2,271;1,149	72,27%
v1	1	8,029	89,21%	zg2	1	6,959	77,32%
v2	1	8,456	93,96%	zg4	1	8,789	97,65%

Lampiran 13. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Pondok Betung

Variabel	Byk. PC	Nilai Eigen	Kum. Varians	Variabel	Byk. PC	Nilai Eigen	Kum. Varians
dpsdt	1	8,998	99,98%	temp2	1	8,753	97,25%
mixr1	1	8,317	92,42%	temp4	1	8,909	98,99%
mixr2	1	8,667	96,3%	tmaxscr	1	8,866	98,51%
mixr4	1	8,766	97,4%	tminscr	1	8,516	94,62%
omega1	1	8,900	98,89%	tpan	1	8,753	97,26%
omega2	1	8,494	94,38%	tscrn	1	8,641	96,01%
omega4	1	8,061	89,57%	u1	1	8,724	96,93%
pblh	1	8,328	92,53%	u2	1	8,802	97,81%
ps	1	8,997	99,97%	u4	1	8,944	99,37%
psl	1	8,998	99,98%	ustar	1	8,177	90,86%
qgscrn	1	8,306	92,29%	v1	1	8,269	91,87%
rh1	1	8,214	91,27%	v2	1	8,210	91,22%
rh2	1	8,599	95,54%	v4	1	8,842	98,25%
rh4	1	8,750	97,23%	zg1	3	4,009; 1,61;1,176	75,51%
rnd	1	7,943	88,26%	zg2	2	6,843;1,224	89,63%
temp1	1	8,665	96,28%	zg4	1	8,767	97,41%

Lampiran 14. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Curug

Variabel	Byk. PC	Nilai Eigen	Kum. Varians	Variabel	Byk. PC	Nilai Eigen	Kum. Varians
dpsdt	1	8,998	99,98%	ps	1	8,968	99,64%
mixr1	1	8,235	91,5%	psl	1	8,998	99,98%
mixr2	1	8,696	96,62%	qgscrn	1	8,168	90,76%
mixr4	1	8,764	97,38%	rh1	1	7,972	88,58%
omega1	1	8,643	96,04%	rh2	1	8,626	95,84%
omega2	1	8,300	92,23%	rh4	1	8,741	97,13%
omega4	1	8,008	88,98%	rnd	1	8,003	88,92%
pblh	1	8,318	92,43%	temp1	1	8,515	94,61%

Lampiran 14. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Curug (lanjutan)

Variabel	Byk. PC	Nilai Eigen	Kum. Varians	Variabel	Byk. PC	Nilai Eigen	Kum. Varians
temp2	1	8,753	97,25%	u4	1	8,944	99,38%
temp4	1	8,907	98,96%	ustar	1	8,092	89,92%
tmaxscr	1	8,840	98,22%	v1	1	8,351	92,79%
tminscr	1	8,332	92,58%	v2	1	8,347	92,74%
tpan	1	8,753	97,25%	v4	1	8,834	98,15%
tscrn	1	8,493	94,37%	zg1	1	7,340	81,55%
u1	1	8,648	96,09%	zg2	2	5,544;2,997	94,91%
u2	1	8,771	97,46%	zg4	2	6,823;2,086	98,99%

Lampiran 15. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Tangerang

Variabel	Byk. PC	Nilai Eigen	Kum. Varians	Variabel	Byk. PC	Nilai Eigen	Kum. Varians
dpsdt	1	8,999	99,98%	temp2	1	8,760	97,33%
mixr1	1	8,282	92,02%	temp4	1	8,914	99,04%
mixr2	1	8,655	96,17%	tmaxscr	1	8,833	98,14%
mixr4	1	8,756	97,29%	tminscr	1	8,441	93,78%
omega1	1	8,874	98,6%	tpan	1	8,728	96,98%
omega2	1	8,502	94,46%	tscrn	1	8,623	95,81%
omega4	1	8,090	89,89%	u1	1	8,754	97,27%
pblh	1	8,225	91,39%	u2	1	8,824	98,05%
ps	1	8,998	99,98%	u4	1	8,948	99,42%
psl	1	8,998	99,98%	ustar	1	8,159	90,66%
qgscrn	1	8,241	91,56%	v1	1	8,416	93,52%
rh1	1	8,106	90,07%	v2	1	8,469	94,1%
rh2	1	8,594	95,49%	v4	1	8,866	98,51%
rh4	1	8,736	97,06%	zg1	3	3,686; 2,028;1,349	78,47%
rnd	1	7,856	87,29%	zg2	2	7,05;1,015	89,6%
temp1	1	8,632	95,91%	zg4	1	8,791	97,68%

Lampiran 16. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Citeko

Variabel	Byk. PC	Nilai Eigen	Kum. Varians	Variabel	Byk. PC	Nilai Eigen	Kum. Varians
dpsdt	1	8,998	99,98%	omega2	2	6,658;1,026	85,38%
mixr1	1	8,045	89,39%	omega4	1	7,242	80,46%
mixr2	1	8,509	94,54%	pblh	1	8,057	89,52%
mixr4	1	8,692	96,57%	ps	1	8,953	99,48%
omega1	2	6,839;1,138	88,64%	psl	1	8,997	99,97%

Lampiran 16. Banyak PC, Nilai Eigen, dan Kumulatif Varians NWP di Stamet Citeko (lanjutan)

Variabel	Byk. PC	Nilai Eigen	Kum. Varians	Variabel	Byk. PC	Nilai Eigen	Kum. Varians
qgscrn	1	7,498	83,31%	tscrn	1	8,388	93,21%
rh1	1	7,783	86,47%	u1	1	8,357	92,86%
rh2	1	8,416	93,51%	u2	1	8,581	95,34%
rh4	1	8,678	96,42%	u4	1	8,916	99,07%
rnd	1	7,920	88%	ustar	2	6,797;1,134	88,13%
temp1	1	8,367	92,96%	v1	2	6,817;1,265	89,79%
temp2	1	8,598	95,54%	v2	2	6,82;1,405	91,38%
temp4	1	8,864	98,49%	v4	1	8,658	96,2%
tmaxscr	1	8,814	97,93%	zg1	1	7,658	85,08%
tminscr	1	8,217	91,30%	zg2	2	6,602;2,091	96,59%
tpan	1	8,536	94,85%	zg4	2	5,999;2,893	98,79%

Lampiran 17. Nilai PRESS Model PLS Stamet Kemayoran

T _{MAKS}	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS
	1	0,8209	13	0,7200	25	0,7235
	2	0,7723	14	0,7204	26	0,7244
	3	0,7419	15	0,7221	27	0,7238
	4	0,7313	16	0,7232	28	0,7238
	5	0,7223	17	0,7259	29	0,7246
	6	0,7183	18	0,7266	30	0,7251
	7	0,7182	19	0,7270	31	0,7255
	8	0,7179	20	0,7269	32	0,7256
	9	0,7177	21	0,7263	33	0,7263
	10	0,7181	22	0,7263	34	0,7257
	11	0,7189	23	0,7263	35	0,7270
	12	0,7183	24	0,7249		
T _{MIN}	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS
	1	0,8933	13	0,8667	25	0,8773
	2	0,8723	14	0,8664	26	0,8752
	3	0,8647	15	0,8662	27	0,8722
	4	0,8640	16	0,8655	28	0,8705
	5	0,8632	17	0,8675	29	0,8709
	6	0,8627	18	0,8678	30	0,8710
	7	0,8648	19	0,8682	31	0,8703
	8	0,8634	20	0,8705	32	0,8702
	9	0,8636	21	0,8690	33	0,8708
	10	0,8668	22	0,8723	34	0,8725
	11	0,8656	23	0,8741	35	0,8727
	12	0,8665	24	0,8757		

Lampiran 18. Nilai PRESS Model PLS Stamet Priok

	Jumlah	Nilai	Jumlah	Nilai	Jumlah	Nilai
	Komponen	PRESS	Komponen	PRESS	Komponen	PRESS
T _{MAKS}	1	0,8349	14	0,7599	27	0,7626
	2	0,7963	15	0,7597	28	0,7631
	3	0,7747	16	0,7600	29	0,7637
	4	0,7642	17	0,7609	30	0,7640
	5	0,7576	18	0,7614	31	0,7641
	6	0,7550	19	0,7613	32	0,7644
	7	0,7553	20	0,7617	33	0,7642
	8	0,7548	21	0,7618	34	0,7643
	9	0,7556	22	0,7619	35	0,7648
	10	0,7569	23	0,7624	36	0,7647
	11	0,7577	24	0,7630	37	0,7643
	12	0,7587	25	0,7628	38	0,7642
	13	0,7598	26	0,7626	39	0,7653
T _{MIN}	Jumlah	Nilai	Jumlah	Nilai	Jumlah	Nilai
	Komponen	PRESS	Komponen	PRESS	Komponen	PRESS
	1	0,9103	14	0,8807	27	0,8837
	2	0,8898	15	0,8804	28	0,8841
	3	0,8785	16	0,8802	29	0,8840
	4	0,8774	17	0,8806	30	0,8841
	5	0,8747	18	0,8803	31	0,8853
	6	0,8735	19	0,8796	32	0,8845
	7	0,8747	20	0,8799	33	0,8858
	8	0,8766	21	0,8809	34	0,8864
	9	0,8761	22	0,8815	35	0,8869
	10	0,8789	23	0,8821	36	0,8862
	11	0,8808	24	0,8830	37	0,8857
	12	0,8793	25	0,8845	38	0,8856
	13	0,8814	26	0,8840	39	0,8873

Lampiran 19. Nilai PRESS Model PLS Stamet Cengkareng

	Jumlah	Nilai	Jumlah	Nilai	Jumlah	Nilai
	Komponen	PRESS	Komponen	PRESS	Komponen	PRESS
T _{MAKS}	1	0,8026	14	0,7058	26	0,7068
	2	0,7595	15	0,7047	27	0,7072
	3	0,7278	16	0,7056	28	0,7070
	4	0,7146	17	0,7063	29	0,7078
	5	0,7052	18	0,7065	30	0,7083
	6	0,7027	19	0,7056	31	0,7098
	7	0,7017	20	0,7056	32	0,7100
	8	0,7024	21	0,7064	33	0,7104
	9	0,7030	22	0,7064	34	0,7102
	10	0,7049	23	0,7065	35	0,7101
	11	0,7047	24	0,7069	36	0,7099
	12	0,7053	25	0,7071	37	0,7100
	13	0,7043				

Lampiran 19. Nilai PRESS Model PLS Stamet Cengkareng (lanjutan)

	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS
T _{MIN}	1	0,9046	14	0,9018	26	0,9085
	2	0,8932	15	0,9018	27	0,9074
	3	0,8916	16	0,9011	28	0,9073
	4	0,8924	17	0,9016	29	0,9071
	5	0,8932	18	0,9018	30	0,9072
	6	0,8936	19	0,9024	31	0,9076
	7	0,8948	20	0,9034	32	0,9077
	8	0,8956	21	0,9054	33	0,9083
	9	0,8969	22	0,9075	34	0,9087
	10	0,9006	23	0,9089	35	0,9089
	11	0,9037	24	0,9100	36	0,9089
	12	0,9022	25	0,9095	37	0,9119
	13	0,9008				

Lampiran 20. Nilai PRESS Model PLS Stamet Pondok Betung

	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS
T _{MAKS}	1	0,8219	13	0,7224	25	0,7161
	2	0,7676	14	0,7227	26	0,7163
	3	0,7360	15	0,7218	27	0,7145
	4	0,7294	16	0,7226	28	0,7150
	5	0,7252	17	0,7215	29	0,7162
	6	0,7247	18	0,7206	30	0,7156
	7	0,7231	19	0,7186	31	0,7155
	8	0,7232	20	0,7185	32	0,7154
	9	0,7218	21	0,7177	33	0,7155
	10	0,7217	22	0,7148	34	0,7150
	11	0,7207	23	0,7153	35	0,7162
	12	0,7221	24	0,7155		
T _{MIN}	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS
	1	0,9273	13	0,9154	25	0,9137
	2	0,9095	14	0,9158	26	0,9120
	3	0,9044	15	0,9166	27	0,9131
	4	0,9013	16	0,9160	28	0,9171
	5	0,9010	17	0,9146	29	0,9168
	6	0,9008	18	0,9152	30	0,9176
	7	0,9016	19	0,9155	31	0,9160
	8	0,9020	20	0,9143	32	0,9141
	9	0,9026	21	0,9156	33	0,9137
	10	0,9052	22	0,9147	34	0,9137
	11	0,9085	23	0,9136	35	0,9150
	12	0,9124	24	0,9128		

Lampiran 21. Nilai PRESS Model PLS Stamet Curug

T_{MAKS}	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS
	1	0,8128	13	0,7111	24	0,7088
	2	0,7604	14	0,7104	25	0,7097
	3	0,7322	15	0,7096	26	0,7103
	4	0,7241	16	0,7091	27	0,7114
	5	0,7158	17	0,7065	28	0,7127
	6	0,7200	18	0,7072	29	0,7122
	7	0,7166	19	0,7069	30	0,7109
	8	0,7140	20	0,7081	31	0,7110
	9	0,7146	21	0,7083	32	0,7110
	10	0,7153	22	0,7079	33	0,7100
	11	0,7113	23	0,7074	34	0,7105
	12	0,7137				
T_{MIN}	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS
	1	0,7788	13	0,7642	24	0,7685
	2	0,7628	14	0,7650	25	0,7670
	3	0,7610	15	0,7652	26	0,7669
	4	0,7608	16	0,7659	27	0,7662
	5	0,7616	17	0,7649	28	0,7664
	6	0,7605	18	0,7655	29	0,7676
	7	0,7606	19	0,7685	30	0,7675
	8	0,7609	20	0,7693	31	0,7676
	9	0,7625	21	0,7680	32	0,7678
	10	0,7637	22	0,7664	33	0,7680
	11	0,7632	23	0,7686	34	0,7688
	12	0,7645				

Lampiran 22. Nilai PRESS Model PLS Stamet Tangerang

T_{MAKS}	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS
	1	0,8083	13	0,7076	25	0,7114
	2	0,7527	14	0,7092	26	0,7118
	3	0,7218	15	0,7105	27	0,7111
	4	0,7153	16	0,7133	28	0,7123
	5	0,7104	17	0,7131	29	0,7126
	6	0,7094	18	0,7154	30	0,7130
	7	0,7096	19	0,7144	31	0,7129
	8	0,7084	20	0,7122	32	0,7133
	9	0,7081	21	0,7121	33	0,7130
	10	0,7076	22	0,7109	34	0,7129
	11	0,7072	23	0,7100	35	0,7142
	12	0,7074	24	0,7104		

Lampiran 22. Nilai PRESS Model PLS Stamet Tangerang (lanjutan)

	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS
T _{MIN}	1	0,9510	13	0,9599	25	0,9662
	2	0,9480	14	0,9615	26	0,9670
	3	0,9484	15	0,9626	27	0,9669
	4	0,9498	16	0,9621	28	0,9670
	5	0,9522	17	0,9608	29	0,9674
	6	0,9531	18	0,9621	30	0,9672
	7	0,9542	19	0,9624	31	0,9677
	8	0,9562	20	0,9627	32	0,9686
	9	0,9574	21	0,9629	33	0,9688
	10	0,9595	22	0,9634	34	0,9688
	11	0,9584	23	0,9636	35	0,9701
	12	0,9580	24	0,9650		

Lampiran 23. Nilai PRESS Model PLS Stamet Citeko

	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS	Jumlah Komponen	Nilai PRESS
T _{MAKS}	1	0,8194	14	0,7314	27	0,7320
	2	0,7814	15	0,7323	28	0,7328
	3	0,7526	16	0,7321	29	0,7339
	4	0,7455	17	0,7338	30	0,7343
	5	0,7396	18	0,7339	31	0,7331
	6	0,7356	19	0,7329	32	0,7331
	7	0,7324	20	0,7332	33	0,7337
	8	0,7302	21	0,7326	34	0,7333
	9	0,7301	22	0,7332	35	0,7334
	10	0,7290	23	0,7327	36	0,7338
	11	0,7287	24	0,7325	37	0,7335
	12	0,7291	25	0,7317	38	0,7333
	13	0,7311	26	0,7314	39	0,7324
T _{MIN}	1	0,8364	14	0,8107	27	0,8204
	2	0,8094	15	0,8129	28	0,8201
	3	0,8079	16	0,8140	29	0,8182
	4	0,8067	17	0,8122	30	0,8171
	5	0,8063	18	0,8118	31	0,8159
	6	0,8046	19	0,8126	32	0,8170
	7	0,8027	20	0,8128	33	0,8181
	8	0,8023	21	0,8131	34	0,8174
	9	0,8038	22	0,8123	35	0,8171
	10	0,8041	23	0,8165	36	0,8175
	11	0,8063	24	0,8185	37	0,8173
	12	0,8103	25	0,8186	38	0,8170
	13	0,8106	26	0,8176	39	0,8164

Lampiran 24. Model Regresi PLS Stamet Dermaga

$$\begin{aligned}
 \hat{y}_{T_{\text{MAKS}}} = & -0,112 \sum_{i=1}^9 e_{i1} \text{dpsdt}_i + 0,13 \sum_{i=1}^9 e_{i2} \text{mixr1}_i + 0,139 \sum_{i=1}^9 e_{i3} \text{mixr2}_i + 0,034 \sum_{i=1}^9 e_{i4} \text{mixr4}_i \\
 & + 0,195 \sum_{i=1}^9 e_{i5} \text{omega1}_i + 0,288 \sum_{i=1}^9 e_{i6} \text{omega1}_i - 0,144 \sum_{i=1}^9 e_{i7} \text{omega2}_i - 0,04 \sum_{i=1}^9 e_{i8} \text{omega2}_i \\
 & - 0,035 \sum_{i=1}^9 e_{i9} \text{omega4}_i - 0,064 \sum_{i=1}^9 e_{i10} \text{omega4}_i - 0,019 \sum_{i=1}^9 e_{i11} \text{pblh}_i + 0,022 \sum_{i=1}^9 e_{i12} \text{ps}_i \\
 & + 0,026 \sum_{i=1}^9 e_{i13} \text{psl}_i - 0,038 \sum_{i=1}^9 e_{i14} \text{qgscrn}_i - 0,081 \sum_{i=1}^9 e_{i15} \text{qgscrn}_i + 0,029 \sum_{i=1}^9 e_{i16} \text{rh1}_i \\
 & - 0,061 \sum_{i=1}^9 e_{i17} \text{rh1}_i + 0,041 \sum_{i=1}^9 e_{i18} \text{rh2}_i + 0,029 \sum_{i=1}^9 e_{i19} \text{rh4}_i + 0,073 \sum_{i=1}^9 e_{i20} \text{rnd}_i - 0,115 \sum_{i=1}^9 e_{i21} \text{temp1}_i \\
 & + 0,318 \sum_{i=1}^9 e_{i22} \text{temp2}_i + 0,017 \sum_{i=1}^9 e_{i23} \text{temp4}_i - 0,538 \sum_{i=1}^9 e_{i24} \text{tmaxscr}_i - 0,128 \sum_{i=1}^9 e_{i25} \text{tminscr}_i \\
 & + 0,092 \sum_{i=1}^9 e_{i26} \text{tpan}_i - 0,169 \sum_{i=1}^9 e_{i27} \text{tsrn}_i - 0,434 \sum_{i=1}^9 e_{i28} \text{u1}_i - 0,415 \sum_{i=1}^9 e_{i29} \text{u2}_i + 0,169 \sum_{i=1}^9 e_{i30} \text{u4}_i \\
 & + 0,081 \sum_{i=1}^9 e_{i31} \text{ustar}_i + 0,013 \sum_{i=1}^9 e_{i32} \text{ustar}_i + 0,049 \sum_{i=1}^9 e_{i33} \text{v1}_i + 0,028 \sum_{i=1}^9 e_{i34} \text{v1}_i - 0,139 \sum_{i=1}^9 e_{i35} \text{v2}_i \\
 & + 0,106 \sum_{i=1}^9 e_{i36} \text{v2}_i - 0,009 \sum_{i=1}^9 e_{i37} \text{v4}_i - 0,086 \sum_{i=1}^9 e_{i38} \text{zg1}_i + 0,02 \sum_{i=1}^9 e_{i39} \text{zg2}_i - 0,0002 \sum_{i=1}^9 e_{i40} \text{zg4}_i \\
 & + 0,067 \sum_{i=1}^9 e_{i41} \text{zg4}_i
 \end{aligned}$$

$$\begin{aligned}
 \hat{y}_{T_{\text{MIN}}} = & 0,003 \sum_{i=1}^9 e_{i1} \text{dpsdt}_i + 0,093 \sum_{i=1}^9 e_{i2} \text{mixr1}_i - 0,077 \sum_{i=1}^9 e_{i3} \text{mixr2}_i + 0,054 \sum_{i=1}^9 e_{i4} \text{mixr4}_i \\
 & + 0,012 \sum_{i=1}^9 e_{i5} \text{omega1}_i + 0,005 \sum_{i=1}^9 e_{i6} \text{omega1}_i + 0,006 \sum_{i=1}^9 e_{i7} \text{omega2}_i + 0,008 \sum_{i=1}^9 e_{i8} \text{omega2}_i \\
 & - 0,008 \sum_{i=1}^9 e_{i9} \text{omega4}_i + 0,044 \sum_{i=1}^9 e_{i10} \text{omega4}_i + 0,048 \sum_{i=1}^9 e_{i11} \text{pblh}_i + 0,02 \sum_{i=1}^9 e_{i12} \text{ps}_i \\
 & + 0,023 \sum_{i=1}^9 e_{i13} \text{psl}_i - 0,089 \sum_{i=1}^9 e_{i14} \text{qgscrn}_i + 0,003 \sum_{i=1}^9 e_{i15} \text{qgscrn}_i - 0,06 \sum_{i=1}^9 e_{i16} \text{rh1}_i - 0,059 \sum_{i=1}^9 e_{i17} \text{rh1}_i \\
 & - 0,045 \sum_{i=1}^9 e_{i18} \text{rh2}_i - 0,009 \sum_{i=1}^9 e_{i19} \text{rh4}_i - 0,011 \sum_{i=1}^9 e_{i20} \text{rnd}_i - 0,029 \sum_{i=1}^9 e_{i21} \text{temp1}_i - 0,043 \sum_{i=1}^9 e_{i22} \text{temp2}_i \\
 & - 0,094 \sum_{i=1}^9 e_{i23} \text{temp4}_i + 0,06 \sum_{i=1}^9 e_{i24} \text{tmaxscr}_i - 0,073 \sum_{i=1}^9 e_{i25} \text{tminscr}_i - 0,005 \sum_{i=1}^9 e_{i26} \text{tpan}_i \\
 & - 0,021 \sum_{i=1}^9 e_{i27} \text{tsrn}_i - 0,002 \sum_{i=1}^9 e_{i28} \text{u1}_i + 0,014 \sum_{i=1}^9 e_{i29} \text{u2}_i + 0,023 \sum_{i=1}^9 e_{i30} \text{u4}_i + 0,051 \sum_{i=1}^9 e_{i31} \text{ustar}_i \\
 & - 0,033 \sum_{i=1}^9 e_{i32} \text{ustar}_i - 0,008 \sum_{i=1}^9 e_{i33} \text{v1}_i - 0,0004 \sum_{i=1}^9 e_{i34} \text{v1}_i - 0,007 \sum_{i=1}^9 e_{i35} \text{v2}_i - 0,007 \sum_{i=1}^9 e_{i36} \text{v2}_i \\
 & - 0,027 \sum_{i=1}^9 e_{i37} \text{v4}_i + 0,02 \sum_{i=1}^9 e_{i38} \text{zg1}_i + 0,012 \sum_{i=1}^9 e_{i39} \text{zg2}_i - 0,059 \sum_{i=1}^9 e_{i40} \text{zg4}_i + 0,06 \sum_{i=1}^9 e_{i41} \text{zg4}_i
 \end{aligned}$$

Lampiran 25. Prakiraan Suhu Maksimum Model PLS

Tanggal	Kemayoran (°C)	Priok (°C)	Cengkareng (°C)	Pd. Betung (°C)
1/1/2009	31,48	31,02	31,18	32,12
1/2/2009	33,59	32,79	32,63	33,73
1/3/2009	33,48	32,65	32,31	33,93
1/4/2009	32,85	32,44	32,36	33,60
1/5/2009	33,29	32,60	32,51	33,75
1/6/2009	31,61	31,06	30,85	32,81
1/7/2009	31,20	30,74	30,39	32,32
1/8/2009	30,87	30,57	30,74	32,06
1/9/2009	30,02	29,83	29,55	31,41
1/10/2009	28,68	29,35	28,53	29,60
1/11/2009	29,83	30,20	29,85	30,71
1/12/2009	28,61	29,34	28,99	29,05
⋮	⋮	⋮	⋮	⋮
12/25/2010	32,16	31,59	31,37	32,88
12/26/2010	31,35	30,95	30,92	32,35
12/27/2010	30,98	30,64	30,74	31,51
12/28/2010	30,93	30,70	30,42	31,43
12/29/2010	31,73	31,32	31,09	32,33
12/30/2010	31,53	30,95	30,93	32,65
12/31/2010	31,87	31,32	31,08	31,99
Tanggal	Curug (°C)	Tangerang (°C)	Citeko (°C)	Dermaga (°C)
1/1/2009	31,28	32,03	24,82	30,86
1/2/2009	32,87	33,55	27,10	31,79
1/3/2009	32,82	33,35	26,40	31,69
1/4/2009	32,68	33,20	26,44	32,33
1/5/2009	32,77	33,62	26,74	32,14
1/6/2009	31,22	31,88	26,33	31,70
1/7/2009	30,67	31,53	25,40	30,48
1/8/2009	30,70	31,74	24,98	30,53
1/9/2009	30,29	30,36	23,57	29,10
1/10/2009	28,58	29,09	22,85	27,98
1/11/2009	30,28	30,71	23,66	29,27
1/12/2009	28,11	29,06	22,05	27,09
⋮	⋮	⋮	⋮	⋮
12/25/2010	31,37	32,38	25,36	31,24
12/26/2010	31,47	32,01	25,42	30,85
12/27/2010	29,97	31,42	23,88	29,13
12/28/2010	30,62	31,23	24,31	29,67
12/29/2010	31,03	31,73	25,68	31,17
12/30/2010	31,68	31,71	25,71	31,89
12/31/2010	30,86	31,63	25,25	30,57

Lampiran 26. Prakiraan Suhu Minimum Model PLS

Tanggal	Kemayoran (°C)	Priok (°C)	Cengkareng (°C)	Pd. Betung (°C)
1/1/2009	24,69	25,16	23,97	23,65
1/2/2009	25,35	25,42	23,77	24,01
1/3/2009	25,17	25,57	23,43	23,43
1/4/2009	24,91	25,38	23,75	23,63
1/5/2009	25,29	25,86	24,25	23,96
1/6/2009	24,97	25,83	23,94	23,73
1/7/2009	24,80	25,28	24,04	23,77
1/8/2009	24,57	25,27	23,92	23,61
1/9/2009	24,26	24,85	23,94	23,08
1/10/2009	23,87	24,13	23,81	23,47
1/11/2009	24,53	24,74	23,75	23,65
1/12/2009	23,76	24,41	23,58	22,60
⋮	⋮	⋮	⋮	⋮
12/25/2010	25,49	25,74	24,53	24,32
12/26/2010	24,94	25,50	24,06	23,75
12/27/2010	24,53	24,98	23,46	23,15
12/28/2010	24,97	24,56	24,17	23,73
12/29/2010	25,39	25,70	24,43	24,29
12/30/2010	25,39	25,65	24,22	23,99
12/31/2010	25,25	24,99	24,03	23,89
Tanggal	Curug (°C)	Tangerang (°C)	Citeko (°C)	Dermaga (°C)
1/1/2009	23,32	23,97	18,23	22,37
1/2/2009	22,84	23,78	18,40	22,56
1/3/2009	22,45	23,40	18,47	21,88
1/4/2009	22,75	23,75	17,96	21,76
1/5/2009	23,21	24,04	18,20	22,05
1/6/2009	23,00	23,77	18,60	22,54
1/7/2009	23,45	23,89	18,80	22,72
1/8/2009	23,27	23,93	18,55	22,67
1/9/2009	23,15	23,71	18,37	22,32
1/10/2009	22,74	23,34	17,94	21,99
1/11/2009	22,81	23,37	17,88	21,89
1/12/2009	22,74	23,40	17,79	21,91
⋮	⋮	⋮	⋮	⋮
12/25/2010	24,14	24,50	18,97	22,80
12/26/2010	23,35	24,00	18,86	22,58
12/27/2010	23,45	23,47	18,45	22,34
12/28/2010	23,70	23,97	18,78	22,82
12/29/2010	23,95	24,18	18,88	22,95
12/30/2010	23,80	24,10	18,75	22,78
12/31/2010	23,78	24,05	18,90	22,68

Lampiran 27. Kumulatif Varians Komponen Prediktor Stamet Kemayoran

Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians
1	23,22	13	94,16	25	99,80
2	40,75	14	95,23	26	99,88
3	52,78	15	96,18	27	99,92
4	61,87	16	96,99	28	99,95
5	68,42	17	97,63	29	99,98
6	73,66	18	98,20	30	99,99
7	78,50	19	98,64	31	99,99
8	82,43	20	98,99	32	100,0
9	85,63	21	99,24	33	100,0
10	88,47	22	99,42	34	100,0
11	90,70	23	99,56	35	100,0
12	92,56	24	99,69		
Keragaman T_{MAKS} terjelaskan				39,82%	
Keragaman T_{MIN} terjelaskan				24,46%	

Lampiran 28. Kumulatif Varians Komponen Prediktor Stamet Priok

Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians
1	21,00	14	91,11	27	99,60
2	37,83	15	92,82	28	99,69
3	48,15	16	94,08	29	99,77
4	56,48	17	95,08	30	99,84
5	62,70	18	95,92	31	99,90
6	68,10	19	96,73	32	99,95
7	72,83	20	97,35	33	99,97
8	76,14	21	97,91	34	99,98
9	79,11	22	98,40	35	99,99
10	81,99	23	98,75	36	100,0
11	84,55	24	99,08	37	100,0
12	86,92	25	99,27	38	100,0
13	89,18	26	99,46	39	100,0
Keragaman T_{MAKS} terjelaskan				36,36%	
Keragaman T_{MIN} terjelaskan				22,2%	

Lampiran 29. Kumulatif Varians Komponen Prediktor Stamet Cengkareng

Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians
1	22,00	14	93,68	27	99,79
2	38,82	15	94,79	28	99,88
3	50,30	16	95,71	29	99,92
4	58,85	17	96,59	30	99,96
5	65,85	18	97,26	31	99,98
6	71,47	19	97,82	32	99,99
7	76,47	20	98,24	33	100,0
8	79,92	21	98,66	34	100,0
9	82,97	22	98,99	35	100,0
10	85,78	23	99,22	36	100,0
11	88,37	24	99,45	37	100,0
12	90,55	25	99,59		
13	92,28	26	99,70		
Keragaman T_{MAKS} terjelaskan				38,78%	
Keragaman T_{MIN} terjelaskan				21,62%	

Lampiran 30. Kumulatif Varians Komponen Prediktor Stamet Pondok Betung

Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians
1	22,79	13	93,19	25	99,80
2	40,09	14	94,84	26	99,87
3	52,50	15	95,98	27	99,92
4	61,22	16	96,84	28	99,95
5	67,66	17	97,62	29	99,98
6	72,63	18	98,18	30	99,99
7	77,42	19	98,63	31	99,99
8	81,09	20	98,92	32	100,0
9	84,28	21	99,20	33	100,0
10	87,18	22	99,39	34	100,0
11	89,45	23	99,56	35	100,0
12	91,47	24	99,70		
Keragaman T_{MAKS} terjelaskan				38,6%	
Keragaman T_{MIN} terjelaskan				17,78%	

Lampiran 31. Kumulatif Varians Komponen Prediktor Stamet Curug

Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians
1	22,22	13	95,51	25	99,91
2	39,70	14	96,61	26	99,94
3	53,05	15	97,40	27	99,96
4	62,18	16	98,09	28	99,98
5	69,72	17	98,59	29	99,99
6	75,86	18	98,92	30	99,99
7	80,93	19	99,23	31	100,0
8	84,87	20	99,43	32	100,0
9	88,10	21	99,58	33	100,0
10	90,61	22	99,71	34	100,0
11	92,62	23	99,80		
12	94,26	24	99,87		
Keragaman T_{MAKS} terjelaskan				31,09%	
Keragaman T_{MIN} terjelaskan				42,93%	

Lampiran 32. Kumulatif Varians Komponen Prediktor Stamet Tangerang

Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians
1	22,52	13	93,43	25	99,77
2	39,65	14	94,56	26	99,84
3	52,20	15	95,66	27	99,91
4	61,19	16	96,60	28	99,95
5	67,74	17	97,42	29	99,97
6	72,93	18	98,01	30	99,99
7	77,94	19	98,46	31	99,99
8	81,68	20	98,80	32	100,0
9	84,74	21	99,08	33	100,0
10	87,55	22	99,32	34	100,0
11	89,99	23	99,50	35	100,0
12	91,85	24	99,65		
Keragaman T_{MAKS} terjelaskan				40,28%	
Keragaman T_{MIN} terjelaskan				12,41%	

Lampiran 33. Kumulatif Varians Komponen Prediktor Stamet Citeko

Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians	Banyak Komponen	%Kum. Varians
1	24,30	14	95,07	27	99,78
2	40,98	15	96,05	28	99,85
3	52,81	16	96,79	29	99,91
4	61,64	17	97,41	30	99,94
5	68,22	18	97,95	31	99,96
6	73,49	19	98,37	32	99,97
7	78,24	20	98,72	33	99,98
8	82,48	21	98,95	34	99,99
9	85,74	22	99,16	35	99,99
10	88,50	23	99,34	36	100,0
11	90,74	24	99,49	37	100,0
12	92,53	25	99,60	38	100,0
13	93,91	26	99,70	39	100,0
Keragaman T_{MAKS} terjelaskan				34,4%	
Keragaman T_{MIN} terjelaskan				35,36%	

Lampiran 34. Model PCR untuk Prakiraan Cuaca Stamet Dermaga

$$\begin{aligned}
\hat{y}_{T_{MAKS}} = & 0,011 \sum_{i=1}^9 e_{i1} dpsdt_i - 0,028 \sum_{i=1}^9 e_{i2} mixr1_i + 0,015 \sum_{i=1}^9 e_{i3} mixr2_i - 0,012 \sum_{i=1}^9 e_{i4} mixr4_i \\
& + 0,004 \sum_{i=1}^9 e_{i5} omega1_i + 0,036 \sum_{i=1}^9 e_{i6} omega1_i + 0,009 \sum_{i=1}^9 e_{i7} omega2_i + 0,03 \sum_{i=1}^9 e_{i8} omega2_i \\
& - 0,009 \sum_{i=1}^9 e_{i9} omega4_i - 0,002 \sum_{i=1}^9 e_{i10} omega4_i - 0,039 \sum_{i=1}^9 e_{i11} pblh_i + 0,042 \sum_{i=1}^9 e_{i12} ps_i \\
& + 0,043 \sum_{i=1}^9 e_{i13} psl_i + 0,021 \sum_{i=1}^9 e_{i14} qgscrn_i - 0,012 \sum_{i=1}^9 e_{i15} qgscrn_i + 0,058 \sum_{i=1}^9 e_{i16} rh1_i \\
& + 0,011 \sum_{i=1}^9 e_{i17} rh1_i + 0,037 \sum_{i=1}^9 e_{i18} rh2_i + 0,024 \sum_{i=1}^9 e_{i19} rh4_i + 0,051 \sum_{i=1}^9 e_{i20} rnd_i - 0,058 \sum_{i=1}^9 e_{i21} temp1_i \\
& - 0,049 \sum_{i=1}^9 e_{i22} temp2_i - 0,028 \sum_{i=1}^9 e_{i23} temp4_i - 0,072 \sum_{i=1}^9 e_{i24} tmaxscr_i - 0,054 \sum_{i=1}^9 e_{i25} tminscr_i \\
& - 0,073 \sum_{i=1}^9 e_{i26} tpan_i - 0,058 \sum_{i=1}^9 e_{i27} tscrn_i - 0,108 \sum_{i=1}^9 e_{i28} u1_i + 0,106 \sum_{i=1}^9 e_{i29} u2_i + 0,095 \sum_{i=1}^9 e_{i30} u4_i \\
& - 0,009 \sum_{i=1}^9 e_{i31} ustar_i - 0,022 \sum_{i=1}^9 e_{i32} ustar_i + 0,009 \sum_{i=1}^9 e_{i33} v1_i + 0,006 \sum_{i=1}^9 e_{i34} v1_i + 0,006 \sum_{i=1}^9 e_{i35} v2_i \\
& + 0,008 \sum_{i=1}^9 e_{i36} v2_i - 0,007 \sum_{i=1}^9 e_{i37} v4_i - 0,005 \sum_{i=1}^9 e_{i38} zg1_i - 0,011 \sum_{i=1}^9 e_{i39} zg2_i - 0,038 \sum_{i=1}^9 e_{i40} zg4_i \\
& + 0,016 \sum_{i=1}^9 e_{i41} zg4_i
\end{aligned}$$

Lampiran 34. Model PCR untuk Prakiraan Cuaca Stamet Dermaga (lanjutan)

$$\begin{aligned}
\hat{y}_{T_{MIN}} = & -0,006 \sum_{i=1}^9 e_{i1} dpsdt_i + 0,087 \sum_{i=1}^9 e_{i2} mixr1_i - 0,063 \sum_{i=1}^9 e_{i3} mixr2_i + 0,064 \sum_{i=1}^9 e_{i4} mixr4_i \\
& -0,002 \sum_{i=1}^9 e_{i5} omega1_i + 0,007 \sum_{i=1}^9 e_{i6} omega1_i + 0,0003 \sum_{i=1}^9 e_{i7} omega2_i + 0,006 \sum_{i=1}^9 e_{i8} omega2_i \\
& -0,012 \sum_{i=1}^9 e_{i9} omega4_i + 0,006 \sum_{i=1}^9 e_{i10} omega4_i + 0,045 \sum_{i=1}^9 e_{i11} pblh_i - 0,023 \sum_{i=1}^9 e_{i12} ps_i \\
& -0,021 \sum_{i=1}^9 e_{i13} psl_i - 0,084 \sum_{i=1}^9 e_{i14} qgscrn_i - 0,012 \sum_{i=1}^9 e_{i15} qgscrn_i - 0,059 \sum_{i=1}^9 e_{i16} rh1_i - 0,027 \sum_{i=1}^9 e_{i17} rh1_i \\
& -0,035 \sum_{i=1}^9 e_{i18} rh2_i - 0,032 \sum_{i=1}^9 e_{i19} rh4_i - 0,005 \sum_{i=1}^9 e_{i20} rnd_i - 0,021 \sum_{i=1}^9 e_{i21} temp1_i - 0,039 \sum_{i=1}^9 e_{i22} temp2_i \\
& -0,056 \sum_{i=1}^9 e_{i23} temp4_i + 0,003 \sum_{i=1}^9 e_{i24} tmaxscr_i - 0,056 \sum_{i=1}^9 e_{i25} tminscr_i - 0,03 \sum_{i=1}^9 e_{i26} tpan_i \\
& -0,016 \sum_{i=1}^9 e_{i27} tscrn_i - 0,022 \sum_{i=1}^9 e_{i28} u1_i + 0,025 \sum_{i=1}^9 e_{i29} u2_i + 0,014 \sum_{i=1}^9 e_{i30} u4_i + 0,022 \sum_{i=1}^9 e_{i31} ustar_i \\
& -0,001 \sum_{i=1}^9 e_{i32} ustar_i + 0,003 \sum_{i=1}^9 e_{i33} v1_i + 0,02 \sum_{i=1}^9 e_{i34} v1_i + 0,001 \sum_{i=1}^9 e_{i35} v2_i - 0,023 \sum_{i=1}^9 e_{i36} v2_i \\
& -0,021 \sum_{i=1}^9 e_{i37} v4_i + 0,013 \sum_{i=1}^9 e_{i38} zg1_i + 0,008 \sum_{i=1}^9 e_{i39} zg2_i - 0,049 \sum_{i=1}^9 e_{i40} zg4_i + 0,042 \sum_{i=1}^9 e_{i41} zg4_i
\end{aligned}$$

Lampiran 35. Prakiraan Suhu Maksimum Model PCR

Tanggal	Kemayoran (°C)	Priok (°C)	Cengkareng (°C)	Pd. Betung (°C)
1/1/2009	30,98	30,94	30,57	31,75
1/2/2009	32,73	32,15	31,66	33,76
1/3/2009	32,99	32,21	31,65	34,27
1/4/2009	31,63	31,49	30,94	32,74
1/5/2009	31,78	31,66	31,07	32,99
1/6/2009	31,51	31,42	30,98	32,23
1/7/2009	30,88	30,89	30,68	31,60
1/8/2009	31,16	30,94	30,92	31,66
1/9/2009	30,23	30,25	30,26	31,09
1/10/2009	29,09	29,61	29,27	29,66
1/11/2009	28,64	29,40	29,58	29,55
1/12/2009	28,80	29,16	29,06	29,70
1/13/2009	28,37	28,62	29,01	29,27
1/14/2009	28,66	28,73	28,81	29,28
⋮	⋮	⋮	⋮	⋮
12/25/2010	32,21	31,96	31,65	32,96
12/26/2010	31,33	31,19	30,89	32,24
12/27/2010	30,80	30,60	30,46	31,28
12/28/2010	31,34	31,18	31,18	32,12
12/29/2010	32,18	32,04	31,59	32,84
12/30/2010	31,73	31,54	31,31	32,59
12/31/2010	31,49	31,00	30,82	32,12

Lampiran 35. Prakiraan Suhu Maksimum Model PCR (lanjutan)

Tanggal	Curug (°C)	Tangerang (°C)	Citeko (°C)	Dermaga (°C)
1/1/2009	30,60	31,25	24,44	30,15
1/2/2009	31,55	33,06	25,95	31,79
1/3/2009	31,93	33,33	25,67	31,51
1/4/2009	31,17	32,09	24,60	30,37
1/5/2009	31,26	32,19	25,14	31,12
1/6/2009	31,54	31,77	24,86	30,25
1/7/2009	31,18	31,29	24,84	30,16
1/8/2009	31,44	31,56	25,01	30,17
1/9/2009	30,75	30,57	23,83	29,26
1/10/2009	29,61	29,79	23,08	28,62
1/11/2009	30,01	29,66	23,34	28,65
1/12/2009	30,19	29,07	23,08	28,36
⋮	⋮	⋮	⋮	⋮
12/26/2010	31,15	31,82	24,30	29,74
12/27/2010	30,00	31,02	23,82	29,23
12/28/2010	31,04	31,63	24,44	29,87
12/29/2010	31,64	32,11	25,68	31,19
12/30/2010	31,43	31,92	25,58	31,37
12/31/2010	30,62	31,53	24,66	30,29

Lampiran 36. Prakiraan Suhu Minimum Model PCR

Tanggal	Kemayoran (°C)	Priok (°C)	Cengkareng (°C)	Pd. Betung (°C)
1/1/2009	24,77	25,11	24,02	23,66
1/2/2009	25,23	25,51	23,60	23,77
1/3/2009	24,97	25,31	23,16	23,44
1/4/2009	24,76	25,22	23,69	23,55
1/5/2009	24,98	25,39	24,12	23,74
1/6/2009	24,87	25,45	23,88	23,89
1/7/2009	24,72	25,26	24,03	23,83
1/8/2009	24,88	25,30	24,00	23,97
1/9/2009	24,41	24,79	24,04	23,38
1/10/2009	23,60	24,35	23,86	22,58
1/11/2009	23,53	24,43	23,97	22,74
1/12/2009	23,77	24,22	23,88	22,94
⋮	⋮	⋮	⋮	⋮
12/26/2010	24,99	25,65	24,11	23,91
12/27/2010	24,39	25,36	23,50	23,11
12/28/2010	24,92	24,99	24,21	23,78
12/29/2010	25,48	25,26	24,47	24,19
12/30/2010	25,16	25,83	24,31	24,08
12/31/2010	25,01	25,57	24,04	23,80

Lampiran 36. Prakiraan Suhu Minimum Model PCR (lanjutan)

Tanggal	Curug (°C)	Tangerang (°C)	Citeko (°C)	Dermaga (°C)
1/1/2009	23,40	23,90	18,35	22,45
1/2/2009	23,06	23,96	18,31	22,48
1/3/2009	22,63	23,65	17,92	21,81
1/4/2009	22,93	23,82	18,01	21,98
1/5/2009	23,24	24,06	18,09	22,14
1/6/2009	22,91	23,69	18,56	22,64
1/7/2009	23,45	23,82	18,82	22,71
1/8/2009	23,38	23,86	18,84	22,70
1/9/2009	23,17	23,59	18,24	22,37
1/10/2009	22,62	23,17	17,75	21,87
1/11/2009	22,67	23,09	17,95	22,11
1/12/2009	22,89	23,20	17,83	22,05
⋮	⋮	⋮	⋮	⋮
12/25/2010	24,03	24,46	18,96	22,85
12/26/2010	23,30	23,98	18,56	22,52
12/27/2010	23,14	23,43	18,16	22,05
12/28/2010	23,68	23,91	18,48	22,46
12/29/2010	23,66	24,09	18,83	22,95
12/30/2010	23,63	23,97	18,66	22,83
12/31/2010	23,65	23,94	18,60	22,55

Lampiran 37. Konstanta λ Terpilih untuk Regresi Ridge

Stamet	λT_{maks}	λT_{min}	Stamet	λT_{maks}	λT_{min}
Cengkareng	1	9	Kemayoran	3	3
Citeko	2	4	Pondok Betung	4	4
Curug	4	9	Priok	8	8
Dermaga	9	9	Tangerang	4	4

Lampiran 38. Model Ridge untuk Prakiraan Cuaca Stamet Dermaga

$$\begin{aligned}
\hat{y}_{T_{MAX}} = & -0,075 \sum_{i=1}^9 e_{i1} dpsdt_i + 0,123 \sum_{i=1}^9 e_{i2} mixr1_i + 0,102 \sum_{i=1}^9 e_{i3} mixr2_i + 0,03 \sum_{i=1}^9 e_{i4} mixr4_i \\
& + 0,153 \sum_{i=1}^9 e_{i5} omega1_i + 0,212 \sum_{i=1}^9 e_{i6} omega1_i - 0,099 \sum_{i=1}^9 e_{i7} omega2_i - 0,029 \sum_{i=1}^9 e_{i8} omega2_i \\
& - 0,017 \sum_{i=1}^9 e_{i9} omega4_i - 0,082 \sum_{i=1}^9 e_{i10} omega4_i - 0,041 \sum_{i=1}^9 e_{i11} pblh_i + 0,024 \sum_{i=1}^9 e_{i12} ps_i \\
& + 0,027 \sum_{i=1}^9 e_{i13} psl_i - 0,005 \sum_{i=1}^9 e_{i14} qgscrn_i - 0,067 \sum_{i=1}^9 e_{i15} qgscrn_i + 0,027 \sum_{i=1}^9 e_{i16} rh1_i \\
& - 0,069 \sum_{i=1}^9 e_{i17} rh1_i + 0,031 \sum_{i=1}^9 e_{i18} rh2_i + 0,037 \sum_{i=1}^9 e_{i19} rh4_i + 0,071 \sum_{i=1}^9 e_{i20} rnd_i - 0,108 \sum_{i=1}^9 e_{i21} temp1_i \\
& + 0,256 \sum_{i=1}^9 e_{i22} temp2_i + 0,008 \sum_{i=1}^9 e_{i23} temp4_i - 0,513 \sum_{i=1}^9 e_{i24} tmaxscr_i - 0,108 \sum_{i=1}^9 e_{i25} tminscr_i \\
& + 0,053 \sum_{i=1}^9 e_{i26} tpan_i - 0,099 \sum_{i=1}^9 e_{i27} tscrn_i - 0,301 \sum_{i=1}^9 e_{i28} u1_i - 0,236 \sum_{i=1}^9 e_{i29} u2_i + 0,141 \sum_{i=1}^9 e_{i30} u4_i \\
& + 0,048 \sum_{i=1}^9 e_{i31} ustar_i + 0,007 \sum_{i=1}^9 e_{i32} ustar_i - 0,012 \sum_{i=1}^9 e_{i33} v1_i + 0,012 \sum_{i=1}^9 e_{i34} v1_i - 0,094 \sum_{i=1}^9 e_{i35} v2_i \\
& + 0,089 \sum_{i=1}^9 e_{i36} v2_i - 0,032 \sum_{i=1}^9 e_{i37} v4_i - 0,096 \sum_{i=1}^9 e_{i38} zg1_i + 0,022 \sum_{i=1}^9 e_{i39} zg2_i \\
& + 0,001 \sum_{i=1}^9 e_{i40} zg4_i + 0,079 \sum_{i=1}^9 e_{i41} zg4_i
\end{aligned}$$

$$\begin{aligned}
\hat{y}_{T_{MIN}} = & -0,099 \sum_{i=1}^9 e_{i1} dpsdt_i - 0,125 \sum_{i=1}^9 e_{i2} mixr1_i - 0,129 \sum_{i=1}^9 e_{i3} mixr2_i + 0,008 \sum_{i=1}^9 e_{i4} mixr4_i \\
& + 0,165 \sum_{i=1}^9 e_{i5} omega1_i + 0,015 \sum_{i=1}^9 e_{i6} omega1_i - 0,051 \sum_{i=1}^9 e_{i7} omega2_i - 0,038 \sum_{i=1}^9 e_{i8} omega2_i \\
& + 0,083 \sum_{i=1}^9 e_{i9} omega4_i + 0,031 \sum_{i=1}^9 e_{i10} omega4_i + 0,01 \sum_{i=1}^9 e_{i11} pblh_i + 0,037 \sum_{i=1}^9 e_{i12} ps_i \\
& + 0,066 \sum_{i=1}^9 e_{i13} psl_i - 0,153 \sum_{i=1}^9 e_{i14} qgscrn_i + 0,054 \sum_{i=1}^9 e_{i15} qgscrn_i - 0,021 \sum_{i=1}^9 e_{i16} rh1_i \\
& - 0,172 \sum_{i=1}^9 e_{i17} rh1_i - 0,261 \sum_{i=1}^9 e_{i18} rh2_i + 0,009 \sum_{i=1}^9 e_{i19} rh4_i - 0,022 \sum_{i=1}^9 e_{i20} rnd_i - 0,083 \sum_{i=1}^9 e_{i21} temp1_i \\
& + 0,066 \sum_{i=1}^9 e_{i22} temp2_i - 0,219 \sum_{i=1}^9 e_{i23} temp4_i + 0,149 \sum_{i=1}^9 e_{i24} tmaxscr_i - 0,084 \sum_{i=1}^9 e_{i25} tminscr_i \\
& - 0,026 \sum_{i=1}^9 e_{i26} tpan_i - 0,01 \sum_{i=1}^9 e_{i27} tscrn_i + 0,055 \sum_{i=1}^9 e_{i28} u1_i + 0,016 \sum_{i=1}^9 e_{i29} u2_i + 0,124 \sum_{i=1}^9 e_{i30} u4_i \\
& + 0,014 \sum_{i=1}^9 e_{i31} ustar_i - 0,088 \sum_{i=1}^9 e_{i32} ustar_i - 0,075 \sum_{i=1}^9 e_{i33} v1_i - 0,049 \sum_{i=1}^9 e_{i34} v1_i + 0,01 \sum_{i=1}^9 e_{i35} v2_i \\
& + 0,053 \sum_{i=1}^9 e_{i36} v2_i - 0,021 \sum_{i=1}^9 e_{i37} v4_i + 0,004 \sum_{i=1}^9 e_{i38} zg1_i - 0,166 \sum_{i=1}^9 e_{i39} zg2_i + 0,022 \sum_{i=1}^9 e_{i40} zg4_i \\
& + 0,29 \sum_{i=1}^9 e_{i41} zg4_i
\end{aligned}$$

Lampiran 39. Prakiraan Suhu Maksimum Model Ridge

Tanggal	Kemayoran (°C)	Priok (°C)	Cengkareng (°C)	Pd. Betung (°C)
1/1/2009	31,46	31,03	31,33	32,20
1/2/2009	33,48	32,83	32,76	33,74
1/3/2009	33,48	32,54	32,20	33,95
1/4/2009	32,89	32,44	32,33	33,53
1/5/2009	33,29	32,50	32,52	33,85
1/6/2009	31,77	31,10	30,95	32,90
1/7/2009	31,30	30,83	30,64	32,34
1/8/2009	31,05	30,76	30,98	32,13
1/9/2009	30,06	29,80	29,60	31,24
1/10/2009	28,77	29,37	28,64	29,75
1/11/2009	29,90	30,24	29,87	30,89
1/12/2009	28,54	29,30	28,84	29,23
⋮	⋮	⋮	⋮	⋮
12/25/2010	32,15	31,60	31,41	32,91
12/26/2010	31,45	30,97	31,05	32,49
12/27/2010	30,99	30,54	30,83	31,47
12/28/2010	30,89	30,79	30,74	31,44
12/29/2010	31,70	31,32	31,07	32,43
12/30/2010	31,51	30,94	30,88	32,70
12/31/2010	31,81	31,26	31,11	32,02
Tanggal	Curug (°C)	Tangerang (°C)	Citeko (°C)	Dermaga (°C)
1/1/2009	31,36	32,03	24,96	30,83
1/2/2009	32,84	33,56	26,96	31,80
1/3/2009	32,74	33,31	26,16	31,85
1/4/2009	32,63	33,25	26,56	32,14
1/5/2009	32,77	33,49	26,80	32,12
1/6/2009	31,36	31,79	26,44	31,52
1/7/2009	30,77	31,55	25,52	30,42
1/8/2009	30,80	31,76	25,11	30,39
1/9/2009	30,40	30,44	23,58	29,16
1/10/2009	28,64	29,04	22,71	28,02
1/11/2009	30,17	30,66	23,80	29,16
1/12/2009	28,13	28,94	22,05	27,16
⋮	⋮	⋮	⋮	⋮
12/25/2010	31,56	32,39	25,26	31,39
12/26/2010	31,49	31,88	25,52	30,73
12/27/2010	30,05	31,41	23,72	29,15
12/28/2010	30,72	31,16	24,18	29,68
12/29/2010	31,20	31,71	25,70	31,14
12/30/2010	31,79	31,67	25,84	31,87
12/31/2010	30,95	31,60	25,14	30,60

Lampiran 40. Prakiraan Suhu Minimum Model Ridge

Tanggal	Kemayoran (°C)	Priok (°C)	Cengkareng (°C)	Pd. Betung (°C)
1/1/2009	24,60	25,23	24,09	23,53
1/2/2009	25,30	25,42	23,82	24,02
1/3/2009	25,06	25,52	23,55	23,31
1/4/2009	24,78	25,19	23,75	23,42
1/5/2009	25,23	25,87	24,46	23,94
1/6/2009	24,97	25,90	24,12	23,55
1/7/2009	24,74	25,34	24,07	23,84
1/8/2009	24,50	25,30	23,83	23,54
1/9/2009	24,22	24,73	23,86	23,01
1/10/2009	23,86	24,20	23,72	23,42
1/11/2009	24,35	24,73	23,78	23,50
1/12/2009	23,67	24,35	23,45	22,64
⋮	⋮	⋮	⋮	⋮
12/25/2010	25,33	25,78	24,64	24,20
12/26/2010	24,87	25,42	24,09	23,60
12/27/2010	24,48	24,85	23,72	23,11
12/28/2010	25,10	24,75	24,21	23,79
12/29/2010	25,40	25,65	24,50	24,24
12/30/2010	25,45	25,62	24,26	23,89
12/31/2010	25,31	25,06	24,12	23,89
Tanggal	Curug (°C)	Tangerang (°C)	Citeko (°C)	Dermaga (°C)
1/1/2009	23,30	24,00	18,24	22,39
1/2/2009	22,82	23,91	18,37	22,44
1/3/2009	22,38	23,76	18,45	21,99
1/4/2009	22,73	23,93	17,91	21,44
1/5/2009	23,24	24,33	18,23	22,02
1/6/2009	23,09	24,13	18,65	22,07
1/7/2009	23,48	23,75	18,78	22,70
1/8/2009	23,28	23,91	18,54	22,56
1/9/2009	23,21	23,61	18,39	22,34
1/10/2009	22,65	23,33	17,98	22,20
1/11/2009	22,73	23,16	17,86	21,71
1/12/2009	22,72	22,71	17,74	21,85
⋮	⋮	⋮	⋮	⋮
12/25/2010	24,08	24,63	18,92	22,80
12/26/2010	23,34	23,90	18,85	22,46
12/27/2010	23,34	23,21	18,46	22,42
12/28/2010	23,68	23,87	18,69	23,22
12/29/2010	23,97	24,43	18,80	22,93
12/30/2010	23,89	24,37	18,76	22,99
12/31/2010	23,74	24,10	18,83	22,93

Lampiran 41. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet Cengkareng dan Citeko, Suhu Maksimum

Cengkareng									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	1,00	0,00	0,00	1,37	0,94	-7,39	1,23	0,78	0,96
20090201	1,00	0,00	0,00	1,05	0,95	-7,73	1,24	0,49	0,97
20090202	1,00	0,00	0,00	2,77	0,89	-6,15	1,19	2,24	0,91
20090203	1,00	0,00	0,00	2,49	0,90	-6,80	1,21	1,79	0,92
20090204	0,93	0,07	0,00	4,31	0,83	-4,96	1,14	3,63	0,86
20090205	0,67	0,33	0,00	4,55	0,82	-4,41	1,12	3,76	0,85
20090206	0,81	0,19	0,00	1,92	0,91	-5,72	1,16	1,24	0,94
20090207	0,77	0,23	0,00	3,24	0,87	-2,79	1,07	2,64	0,90
20090208	0,64	0,36	0,00	2,15	0,91	-3,28	1,08	1,69	0,93
20090209	0,80	0,20	0,00	2,21	0,91	-3,48	1,09	1,73	0,93
20090210	0,79	0,21	0,00	1,82	0,92	-2,88	1,07	1,34	0,94
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	0,47	0,00	0,53	5,95	0,81	10,43	0,66	6,39	0,79
20101229	0,26	0,00	0,74	6,35	0,79	9,67	0,68	6,82	0,78
20101230	0,07	0,00	0,93	5,85	0,81	6,20	0,80	6,33	0,79
20101231	0,08	0,00	0,92	6,76	0,78	10,42	0,66	7,59	0,75
Citeko									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	1,00	0,00	0,00	-2,77	1,08	-8,00	1,29	-2,27	1,06
20090201	1,00	0,00	0,00	-2,00	1,06	-7,07	1,26	-1,29	1,03
20090202	1,00	0,00	0,00	-1,27	1,03	-5,02	1,17	-0,49	0,99
20090203	1,00	0,00	0,00	2,40	0,88	2,61	0,86	3,19	0,84
20090204	1,00	0,00	0,00	5,79	0,74	6,00	0,72	6,46	0,71
20090205	1,00	0,00	0,00	5,91	0,73	6,10	0,71	6,63	0,70
20090206	1,00	0,00	0,00	5,50	0,74	6,19	0,70	6,25	0,71
20090207	1,00	0,00	0,00	3,68	0,82	4,48	0,76	4,36	0,79
20090208	0,94	0,00	0,06	0,84	0,94	1,99	0,87	1,40	0,92
20090209	0,99	0,00	0,01	1,03	0,93	1,66	0,88	1,79	0,90
20090210	0,68	0,00	0,32	0,37	0,96	0,86	0,91	1,00	0,93
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	0,99	0,00	0,01	16,90	0,32	19,64	0,21	17,13	0,31
20101229	0,97	0,00	0,03	16,53	0,34	19,01	0,24	16,74	0,33
20101230	0,99	0,00	0,01	15,38	0,38	16,28	0,35	15,75	0,37
20101231	0,99	0,00	0,01	16,44	0,34	18,90	0,24	16,91	0,32

Lampiran 42. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet Curug dan Dermaga, Suhu Maksimum

Curug									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	1,00	0,00	0,00	-0,64	1,01	-11,44	1,35	-0,60	1,00
20090201	1,00	0,00	0,00	-0,76	1,01	-14,17	1,43	-0,69	1,01
20090202	1,00	0,00	0,00	-1,76	1,04	-8,59	1,24	-1,60	1,03
20090203	1,00	0,00	0,00	-0,43	0,99	-2,90	1,06	0,05	0,98
20090204	0,97	0,03	0,00	2,97	0,88	0,25	0,95	3,60	0,86
20090205	0,98	0,02	0,00	6,04	0,78	2,21	0,88	6,66	0,76
20090206	0,87	0,10	0,03	4,55	0,83	-0,55	0,97	4,96	0,81
20090207	0,84	0,07	0,08	4,97	0,81	0,50	0,94	5,34	0,80
20090208	0,85	0,05	0,10	5,16	0,81	1,07	0,92	5,47	0,80
20090209	0,29	0,10	0,61	4,53	0,83	0,50	0,94	4,68	0,83
20090210	0,03	0,12	0,84	5,03	0,82	-0,07	0,96	5,10	0,81
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	0,00	0,86	0,14	16,44	0,47	5,83	0,81	15,28	0,51
20101229	0,00	0,75	0,25	17,15	0,45	8,19	0,73	16,17	0,48
20101230	0,00	0,34	0,66	19,87	0,36	13,59	0,55	19,19	0,38
20101231	0,00	0,33	0,67	21,53	0,30	16,51	0,46	20,70	0,33
Dermaga									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	0,00	0,00	1,00	1,37	0,94	-7,39	1,23	0,78	0,96
20090201	0,00	0,00	1,00	1,05	0,95	-7,73	1,24	0,49	0,97
20090202	0,00	0,00	1,00	2,77	0,89	-6,15	1,19	2,24	0,91
20090203	0,02	0,00	0,98	2,49	0,90	-6,80	1,21	1,79	0,92
20090204	0,00	0,00	1,00	4,31	0,83	-4,96	1,14	3,63	0,86
20090205	0,02	0,00	0,98	4,55	0,82	-4,41	1,12	3,76	0,85
20090206	0,72	0,00	0,28	1,92	0,91	-5,72	1,16	1,24	0,94
20090207	0,93	0,00	0,07	3,24	0,87	-2,79	1,07	2,64	0,90
20090208	0,99	0,00	0,01	2,15	0,91	-3,28	1,08	1,69	0,93
20090209	0,95	0,00	0,05	2,21	0,91	-3,48	1,09	1,73	0,93
20090210	0,96	0,00	0,04	1,82	0,92	-2,88	1,07	1,34	0,94
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	1,00	0,00	0,00	5,95	0,81	10,43	0,66	6,39	0,79
20101229	1,00	0,00	0,00	6,35	0,79	9,67	0,68	6,82	0,78
20101230	1,00	0,00	0,00	5,85	0,81	6,20	0,80	6,33	0,79
20101231	1,00	0,00	0,00	6,76	0,78	10,42	0,66	7,59	0,75

Lampiran 43. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet
Kemayoran dan Pondok Betung, Suhu Maksimum

Kemayoran									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	0,83	0,00	0,17	-5,29	1,16	-4,99	1,15	-5,44	1,16
20090201	0,79	0,00	0,21	-5,21	1,16	-5,08	1,15	-5,28	1,16
20090202	1,00	0,00	0,00	-5,23	1,16	-4,07	1,12	-4,90	1,15
20090203	0,95	0,04	0,01	-4,17	1,12	-1,56	1,03	-3,75	1,11
20090204	0,43	0,17	0,40	1,86	0,92	4,10	0,84	2,14	0,91
20090205	0,00	0,35	0,65	9,84	0,65	10,49	0,63	10,02	0,65
20090206	0,00	0,25	0,75	8,15	0,71	9,69	0,65	8,15	0,71
20090207	0,00	0,29	0,71	8,04	0,71	9,80	0,65	7,98	0,72
20090208	0,00	0,31	0,69	8,75	0,69	11,26	0,60	8,66	0,69
20090209	0,00	0,22	0,78	8,71	0,69	12,65	0,56	8,63	0,69
20090210	0,00	0,20	0,80	6,90	0,75	11,99	0,58	7,01	0,75
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	0,87	0,00	0,13	13,10	0,59	17,27	0,46	12,50	0,61
20101229	0,99	0,00	0,01	12,53	0,61	15,17	0,53	11,96	0,63
20101230	0,99	0,00	0,01	13,41	0,59	16,89	0,47	12,81	0,60
20101231	0,99	0,00	0,01	14,26	0,56	20,52	0,35	13,72	0,58
Pondok Betung									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	0,71	0,29	0,00	-3,05	1,09	-2,93	1,08	-3,26	1,09
20090201	0,74	0,26	0,00	-3,35	1,09	-3,46	1,10	-3,62	1,10
20090202	0,71	0,29	0,00	-2,74	1,08	-3,87	1,11	-3,19	1,09
20090203	0,65	0,23	0,11	-3,93	1,11	-6,45	1,19	-4,49	1,13
20090204	0,36	0,31	0,34	-1,16	1,02	-2,62	1,07	-1,59	1,03
20090205	0,59	0,40	0,01	4,55	0,84	3,38	0,87	4,09	0,85
20090206	0,00	0,21	0,79	1,08	0,95	1,92	0,92	0,18	0,98
20090207	0,00	0,31	0,69	2,70	0,89	3,00	0,88	1,82	0,92
20090208	0,00	0,30	0,70	2,62	0,90	4,28	0,84	1,69	0,93
20090209	0,79	0,13	0,08	2,29	0,91	7,55	0,73	1,94	0,92
20090210	0,75	0,19	0,06	1,37	0,94	6,40	0,77	1,00	0,95
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	0,91	0,08	0,00	11,62	0,64	12,15	0,62	12,02	0,63
20101229	1,00	0,00	0,00	11,89	0,63	12,60	0,60	12,28	0,62
20101230	1,00	0,00	0,00	12,60	0,61	13,37	0,58	13,31	0,59
20101231	1,00	0,00	0,00	11,44	0,65	13,13	0,59	12,35	0,62

Lampiran 44. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet Tangerang dan Priok, Suhu Maksimum

Tangerang									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	0,98	0,00	0,02	-0,05	0,98	-0,31	0,99	0,19	0,98
20090201	0,99	0,00	0,01	0,46	0,97	-0,39	0,99	0,68	0,96
20090202	1,00	0,00	0,00	1,23	0,94	0,91	0,95	1,49	0,93
20090203	0,99	0,00	0,01	2,00	0,92	1,74	0,92	2,29	0,91
20090204	0,96	0,03	0,00	6,91	0,75	7,14	0,74	7,10	0,75
20090205	0,15	0,23	0,62	10,93	0,62	11,27	0,61	11,18	0,61
20090206	0,82	0,18	0,00	8,08	0,72	9,34	0,67	8,67	0,70
20090207	0,80	0,20	0,00	7,69	0,73	9,28	0,67	8,29	0,71
20090208	0,87	0,13	0,00	8,27	0,71	11,50	0,60	8,88	0,69
20090209	0,59	0,14	0,28	8,45	0,71	12,57	0,57	8,86	0,69
20090210	0,39	0,11	0,50	7,34	0,74	12,30	0,57	7,73	0,73
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	0,00	0,00	1,00	17,21	0,46	17,72	0,44	16,48	0,48
20101229	0,00	0,00	1,00	17,75	0,44	18,90	0,40	17,07	0,46
20101230	0,00	0,00	1,00	17,65	0,44	17,29	0,45	16,82	0,47
20101231	0,00	0,00	1,00	19,63	0,38	22,72	0,28	18,82	0,41
Priok									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	0,88	0,12	0,00	-10,31	1,33	-9,19	1,29	-10,24	1,33
20090201	0,89	0,11	0,00	-10,08	1,32	-9,49	1,30	-10,15	1,32
20090202	0,96	0,04	0,00	-12,52	1,41	-10,13	1,32	-12,71	1,41
20090203	0,86	0,14	0,00	-9,56	1,31	-6,56	1,20	-9,42	1,30
20090204	0,71	0,29	0,00	-6,17	1,19	-2,71	1,07	-5,90	1,19
20090205	0,56	0,44	0,00	-3,42	1,10	1,72	0,92	-2,74	1,08
20090206	0,55	0,45	0,00	-2,73	1,08	2,37	0,90	-1,98	1,05
20090207	0,49	0,47	0,03	-3,14	1,09	2,31	0,90	-2,47	1,07
20090208	0,00	0,53	0,46	-3,50	1,10	3,50	0,86	-3,18	1,09
20090209	0,59	0,40	0,01	-2,25	1,06	7,57	0,73	-1,81	1,05
20090210	0,59	0,40	0,00	-2,17	1,06	7,73	0,73	-1,64	1,04
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	0,07	0,00	0,93	6,91	0,78	10,47	0,67	6,01	0,81
20101229	0,01	0,00	0,99	8,24	0,74	11,94	0,62	7,23	0,77
20101230	0,01	0,00	0,99	8,12	0,75	10,93	0,65	7,15	0,78
20101231	0,04	0,00	0,96	9,57	0,70	14,27	0,54	8,66	0,73

Lampiran 45. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet Cengkareng dan Citeko, Suhu Minimum

Cengkareng									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	0,32	0,21	0,47	-4,99	1,21	-3,79	1,15	0,15	0,99
20090201	0,38	0,25	0,36	-4,79	1,20	-3,85	1,15	0,56	0,97
20090202	0,16	0,66	0,18	-6,44	1,26	-9,21	1,37	-0,38	1,01
20090203	0,04	0,51	0,45	-3,66	1,15	-10,95	1,45	1,99	0,91
20090204	0,50	0,00	0,50	-2,63	1,11	-8,38	1,34	2,77	0,88
20090205	0,28	0,00	0,72	-10,73	1,44	-16,35	1,67	-4,87	1,20
20090206	0,26	0,00	0,74	-9,33	1,39	-14,65	1,60	-4,35	1,18
20090207	0,28	0,00	0,72	-10,81	1,45	-14,67	1,60	-5,35	1,22
20090208	0,28	0,00	0,72	-12,08	1,50	-15,57	1,64	-6,14	1,26
20090209	0,23	0,00	0,77	-9,08	1,38	-13,11	1,54	-3,75	1,16
20090210	0,00	0,00	1,00	-8,69	1,36	-10,75	1,44	-4,37	1,18
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	0,01	0,00	0,99	15,93	0,33	18,27	0,24	15,83	0,34
20101229	0,02	0,00	0,98	16,68	0,30	19,17	0,20	16,63	0,30
20101230	0,04	0,11	0,85	19,19	0,20	24,65	-0,03	19,13	0,20
20101231	0,47	0,00	0,52	17,55	0,27	22,52	0,06	18,05	0,24
Citeko									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	0,00	0,00	1,00	13,21	0,28	14,58	0,20	12,52	0,32
20090201	0,00	0,00	1,00	12,72	0,30	14,69	0,20	12,11	0,34
20090202	0,00	0,00	1,00	12,68	0,31	14,79	0,19	12,16	0,34
20090203	0,00	0,00	1,00	12,67	0,31	15,46	0,16	11,98	0,35
20090204	0,00	0,00	1,00	14,42	0,21	16,41	0,11	14,06	0,23
20090205	0,00	0,00	1,00	14,45	0,21	15,92	0,13	13,84	0,25
20090206	0,00	0,00	1,00	12,72	0,31	15,01	0,18	11,94	0,35
20090207	0,00	0,00	1,00	13,34	0,27	15,35	0,16	12,53	0,32
20090208	0,00	0,00	1,00	13,31	0,27	15,22	0,17	12,16	0,34
20090209	0,00	0,00	1,00	14,02	0,23	15,27	0,17	12,96	0,29
20090210	0,00	0,00	1,00	12,09	0,34	13,83	0,24	11,16	0,39
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	1,00	0,00	0,00	8,33	0,55	10,91	0,41	9,38	0,49
20101229	1,00	0,00	0,00	8,14	0,56	10,28	0,45	9,01	0,51
20101230	1,00	0,00	0,00	7,62	0,59	10,17	0,45	8,38	0,55
20101231	1,00	0,00	0,00	5,54	0,70	8,50	0,54	6,18	0,66

Lampiran 46. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet Curug dan Dermaga, Suhu Minimum

Curug									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	1,00	0,00	0,00	-12,52	1,54	-15,74	1,68	-10,01	1,43
20090201	1,00	0,00	0,00	-11,74	1,51	-14,58	1,63	-9,38	1,41
20090202	1,00	0,00	0,00	-10,07	1,44	-12,92	1,56	-7,65	1,33
20090203	1,00	0,00	0,00	-2,36	1,11	-4,23	1,19	0,07	1,00
20090204	0,87	0,13	0,00	-3,06	1,14	-5,54	1,24	-0,44	1,02
20090205	0,91	0,09	0,00	-4,06	1,18	-6,45	1,28	-1,47	1,07
20090206	0,99	0,01	0,00	-3,81	1,17	-6,00	1,26	-1,52	1,07
20090207	1,00	0,00	0,00	-6,69	1,29	-8,34	1,36	-4,29	1,19
20090208	1,00	0,00	0,00	-7,03	1,31	-8,56	1,37	-4,53	1,20
20090209	0,81	0,19	0,00	-7,93	1,35	-8,97	1,39	-5,70	1,25
20090210	0,52	0,48	0,00	-8,67	1,38	-12,72	1,55	-7,13	1,31
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	0,00	0,83	0,17	8,12	0,66	5,67	0,76	8,13	0,66
20101229	0,00	1,00	0,00	8,84	0,62	6,06	0,74	8,71	0,63
20101230	0,00	0,94	0,05	7,78	0,67	5,47	0,77	7,90	0,66
20101231	0,00	0,73	0,27	7,07	0,70	5,51	0,76	6,97	0,70
Dermaga									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	0,00	0,00	1,00	5,54	0,74	5,91	0,72	0,05	0,98
20090201	0,00	0,00	1,00	5,39	0,74	6,70	0,68	0,21	0,97
20090202	0,00	0,00	1,00	5,85	0,72	6,90	0,67	0,72	0,95
20090203	0,00	0,00	1,00	7,66	0,64	9,64	0,55	1,72	0,91
20090204	0,00	0,00	1,00	11,90	0,45	13,62	0,38	5,56	0,74
20090205	0,00	0,00	1,00	15,84	0,28	17,42	0,21	9,63	0,56
20090206	0,00	0,00	1,00	13,66	0,38	13,54	0,39	12,52	0,43
20090207	0,00	0,09	0,90	11,97	0,46	11,51	0,48	11,09	0,50
20090208	0,00	0,01	0,99	11,09	0,50	10,74	0,51	10,22	0,53
20090209	0,00	0,00	1,00	11,04	0,50	10,74	0,51	10,28	0,53
20090210	0,00	0,02	0,98	10,37	0,53	9,61	0,56	10,02	0,54
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	0,00	0,00	1,00	13,14	0,43	19,42	0,15	10,84	0,53
20101229	0,24	0,00	0,76	10,85	0,53	17,71	0,23	9,77	0,57
20101230	0,03	0,00	0,97	7,67	0,67	16,12	0,30	5,50	0,76
20101231	0,04	0,00	0,96	2,75	0,89	11,64	0,50	0,26	0,99

Lampiran 47. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet
Kemayoran dan Pondok Betung, Suhu Minimum

Kemayoran									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	0,08	0,00	0,92	3,52	0,85	9,79	0,60	3,60	0,85
20090201	0,57	0,00	0,43	3,01	0,87	9,29	0,62	3,15	0,87
20090202	0,56	0,00	0,44	2,42	0,90	9,09	0,63	2,87	0,88
20090203	1,00	0,00	0,00	0,68	0,97	7,65	0,68	1,40	0,94
20090204	1,00	0,00	0,00	0,25	0,98	6,90	0,71	0,94	0,96
20090205	0,96	0,00	0,04	1,09	0,95	7,19	0,70	1,90	0,92
20090206	0,98	0,00	0,02	-0,89	1,03	6,00	0,75	0,01	0,99
20090207	0,89	0,00	0,11	-0,65	1,02	6,22	0,74	0,30	0,98
20090208	1,00	0,00	0,00	-1,71	1,06	3,85	0,84	-0,39	1,01
20090209	1,00	0,00	0,00	-0,26	1,01	5,79	0,76	0,90	0,96
20090210	1,00	0,00	0,00	-1,45	1,05	5,04	0,79	0,04	0,99
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	1,00	0,00	0,00	18,36	0,26	20,79	0,17	20,23	0,19
20101229	1,00	0,00	0,00	18,28	0,27	20,80	0,17	20,21	0,19
20101230	1,00	0,00	0,00	15,36	0,39	17,34	0,30	17,08	0,32
20101231	1,00	0,00	0,00	12,26	0,51	16,50	0,34	13,84	0,45
Pondok Betung									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	0,23	0,00	0,77	-2,53	1,09	10,18	0,54	-4,77	1,19
20090201	0,01	0,00	0,99	-1,25	1,03	11,16	0,50	-3,98	1,15
20090202	0,17	0,00	0,83	2,05	0,89	13,21	0,41	-0,02	0,98
20090203	0,01	0,00	0,99	3,27	0,84	13,19	0,41	0,89	0,94
20090204	0,23	0,00	0,77	2,78	0,86	12,96	0,42	0,83	0,94
20090205	0,01	0,00	0,99	0,44	0,97	11,73	0,48	-2,72	1,10
20090206	0,19	0,00	0,81	-0,98	1,03	10,30	0,54	-3,65	1,14
20090207	0,00	0,00	1,00	-4,96	1,20	6,23	0,72	-9,63	1,41
20090208	0,00	0,00	1,00	-3,98	1,16	7,67	0,66	-8,86	1,37
20090209	0,00	0,00	1,00	-3,11	1,13	7,50	0,67	-7,05	1,30
20090210	0,37	0,00	0,63	-3,13	1,13	4,05	0,81	-6,28	1,27
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	0,01	0,08	0,92	25,79	-0,08	26,23	-0,10	26,08	-0,09
20101229	0,01	0,00	0,98	24,86	-0,04	24,54	-0,03	25,30	-0,06
20101230	0,32	0,00	0,68	28,34	-0,19	27,92	-0,17	28,43	-0,19
20101231	0,99	0,00	0,00	30,61	-0,29	31,07	-0,31	29,75	-0,25

Lampiran 48. Estimasi Bobot dan Koefisien Regresi Model BMA untuk Stamet Tangerang dan Priok, Suhu Minimum

Tangerang									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	0,16	0,20	0,64	-25,14	2,06	-15,76	1,67	-5,04	1,22
20090201	0,14	0,18	0,67	-24,84	2,05	-15,51	1,66	-4,79	1,21
20090202	0,00	0,22	0,78	-27,75	2,17	-19,59	1,83	-7,60	1,32
20090203	0,14	0,11	0,75	-30,30	2,28	-19,33	1,82	-6,81	1,29
20090204	0,53	0,02	0,46	-33,17	2,39	-21,21	1,90	-6,81	1,29
20090205	0,69	0,00	0,31	-29,73	2,25	-17,79	1,76	-3,46	1,15
20090206	0,60	0,00	0,40	-27,97	2,18	-17,58	1,75	-3,82	1,16
20090207	0,61	0,00	0,39	-29,79	2,25	-19,28	1,82	-4,08	1,17
20090208	0,00	0,45	0,55	-29,43	2,24	-22,09	1,94	-5,57	1,24
20090209	0,00	0,51	0,49	-28,73	2,20	-24,06	2,02	-6,45	1,27
20090210	0,00	0,56	0,44	-32,88	2,38	-26,67	2,13	-6,94	1,29
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	0,70	0,11	0,18	36,41	-0,53	35,17	-0,48	22,15	0,07
20101229	0,62	0,02	0,36	33,44	-0,41	31,93	-0,34	19,74	0,16
20101230	0,08	0,00	0,92	25,94	-0,09	19,97	0,16	13,45	0,43
20101231	0,00	0,00	1,00	21,91	0,08	16,20	0,32	7,83	0,67
Priok									
Tanggal	Bobot			PLS		PCR		Ridge	
	PLS	PCR	Ridge	β_0	β_1	β_0	β_1	β_0	β_1
20090131	0,00	0,55	0,45	-3,53	1,14	-4,66	1,18	-3,27	1,13
20090201	0,00	0,48	0,52	-4,37	1,17	-5,29	1,21	-4,00	1,16
20090202	0,00	0,50	0,50	-5,21	1,20	-6,56	1,26	-4,79	1,19
20090203	0,00	0,57	0,43	-5,75	1,22	-6,74	1,27	-5,20	1,20
20090204	0,00	0,60	0,40	-6,17	1,24	-6,80	1,27	-5,35	1,21
20090205	0,00	0,65	0,35	-5,81	1,23	-4,26	1,17	-5,05	1,20
20090206	0,00	0,67	0,33	-6,46	1,25	-3,62	1,14	-5,92	1,23
20090207	0,00	0,71	0,29	-6,10	1,24	-3,65	1,14	-5,63	1,22
20090208	0,00	0,65	0,35	-6,88	1,27	-3,51	1,14	-6,25	1,25
20090209	0,00	0,32	0,68	-13,12	1,52	-8,55	1,34	-11,75	1,47
20090210	0,00	0,22	0,78	-14,35	1,57	-8,57	1,34	-12,52	1,50
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
20101228	0,00	0,00	1,00	14,07	0,44	17,46	0,31	11,54	0,54
20101229	0,00	0,00	1,00	8,74	0,65	15,98	0,36	7,10	0,72
20101230	0,04	0,00	0,96	5,13	0,80	8,38	0,67	3,68	0,85
20101231	0,33	0,00	0,67	-1,52	1,06	1,58	0,94	-2,83	1,11

Lampiran 49. Prakiraan Suhu Maksimum BMA

Tanggal	Kemayoran (°C)	Priok (°C)	Cengkareng (°C)	Pd. Betung (°C)
1/31/2009	28,78	28,81	28,16	29,64
2/1/2009	28,31	28,69	28,42	29,46
2/2/2009	27,91	28,09	27,49	29,37
2/3/2009	28,05	28,45	28,02	29,27
2/4/2009	27,81	27,74	27,81	27,97
2/5/2009	29,29	29,45	28,87	30,25
2/6/2009	28,99	29,01	28,79	29,56
2/7/2009	28,99	28,50	28,97	29,58
2/8/2009	28,65	28,17	28,47	28,96
2/9/2009	29,46	29,82	28,87	29,97
2/10/2009	30,06	30,35	29,80	30,73
2/11/2009	30,51	31,09	30,18	31,45
⋮	⋮	⋮	⋮	⋮
12/25/2010	32,35	31,63	31,61	32,74
12/26/2010	31,81	31,18	31,30	32,41
12/27/2010	31,52	30,90	31,09	31,80
12/28/2010	31,48	31,02	30,96	31,76
12/29/2010	32,03	31,45	31,31	32,28
12/30/2010	31,86	31,17	31,13	32,46
12/31/2010	32,04	31,44	31,29	32,06
Tanggal	Curug (°C)	Tangerang (°C)	Citeko (°C)	Dermaga (°C)
1/31/2009	28,88	29,02	22,72	28,13
2/1/2009	28,60	29,20	22,24	28,27
2/2/2009	28,27	28,43	21,54	27,18
2/3/2009	28,41	28,76	22,25	27,36
2/4/2009	27,37	28,37	21,58	26,61
2/5/2009	28,91	29,56	22,36	27,43
2/6/2009	28,57	29,36	22,10	27,38
2/7/2009	29,26	29,53	22,46	28,30
2/8/2009	28,57	28,99	21,96	27,12
2/9/2009	28,91	29,57	22,62	28,04
2/10/2009	29,78	30,36	24,19	29,85
2/11/2009	29,76	30,68	24,39	30,06
⋮	⋮	⋮	⋮	⋮
12/25/2010	31,24	32,17	25,12	31,11
12/26/2010	30,82	31,85	25,10	30,80
12/27/2010	29,79	31,62	24,59	29,45
12/28/2010	30,85	31,52	24,74	29,85
12/29/2010	31,25	31,75	25,17	31,08
12/30/2010	31,12	31,69	25,24	31,67
12/31/2010	30,76	31,65	25,02	30,56

Lampiran 50. Prakiraan Suhu Minimum BMA

Tanggal	Kemayoran (°C)	Priok (°C)	Cengkareng (°C)	Pd. Betung (°C)
1/31/2009	24,09	24,58	23,74	22,86
2/1/2009	23,86	24,42	23,62	22,44
2/2/2009	23,83	24,30	23,39	22,39
2/3/2009	23,84	24,39	23,81	22,46
2/4/2009	23,29	23,41	23,22	22,09
2/5/2009	24,08	24,48	23,47	22,69
2/6/2009	23,79	24,00	23,27	22,29
2/7/2009	24,09	23,56	23,27	22,82
2/8/2009	23,81	23,34	23,09	23,09
2/9/2009	24,13	24,48	23,85	22,90
2/10/2009	24,53	25,21	24,00	23,40
2/11/2009	24,66	25,09	24,46	23,95
⋮	⋮	⋮	⋮	⋮
12/25/2010	24,95	25,37	24,16	23,84
12/26/2010	24,93	25,38	23,92	23,87
12/27/2010	24,84	25,09	23,69	23,92
12/28/2010	24,95	25,01	23,96	23,90
12/29/2010	25,06	25,51	24,06	23,85
12/30/2010	25,16	25,58	23,94	23,79
12/31/2010	25,19	25,09	23,94	23,73
Tanggal	Curug (°C)	Tangerang (°C)	Citeko (°C)	Dermaga (°C)
1/31/2009	23,11	23,48	18,30	22,04
2/1/2009	22,99	23,24	18,26	21,85
2/2/2009	22,93	22,86	18,32	21,84
2/3/2009	23,09	23,47	18,26	21,80
2/4/2009	23,10	22,86	18,31	22,06
2/5/2009	23,09	23,01	18,30	22,03
2/6/2009	22,89	23,19	18,28	22,11
2/7/2009	23,25	23,75	18,30	22,05
2/8/2009	23,49	23,31	18,37	22,33
2/9/2009	23,46	23,36	18,27	22,32
2/10/2009	23,65	23,96	18,37	22,27
2/11/2009	23,88	24,00	18,21	22,05
⋮	⋮	⋮	⋮	⋮
12/25/2010	23,86	23,42	18,79	22,85
12/26/2010	23,39	23,83	18,69	22,61
12/27/2010	23,25	24,02	18,44	22,58
12/28/2010	23,63	23,78	18,64	23,06
12/29/2010	23,58	23,67	18,68	22,93
12/30/2010	23,58	23,93	18,61	22,99
12/31/2010	23,62	23,95	18,71	23,01

Lampiran 51. Prakiraan Suhu Maksimum GOP

Tanggal	Kemayoran (°C)	Priok (°C)	Cengkareng (°C)	Pd. Betung (°C)
1/31/2009	26,82	26,48	28,75	27,80
2/1/2009	28,36	28,03	30,73	28,11
2/2/2009	25,52	27,21	28,20	31,01
2/3/2009	28,51	28,74	30,11	30,85
2/4/2009	25,42	24,33	27,23	24,53
2/5/2009	25,25	29,09	26,93	26,80
2/6/2009	28,18	30,16	29,13	26,37
2/7/2009	26,24	28,50	28,69	30,16
2/8/2009	26,22	25,47	29,08	26,62
2/9/2009	23,87	27,85	27,52	26,52
2/10/2009	27,64	26,70	31,47	30,89
2/11/2009	30,77	28,10	26,53	28,69
⋮	⋮	⋮	⋮	⋮
12/25/2010	30,78	29,98	29,13	32,48
12/26/2010	34,78	34,52	32,03	33,35
12/27/2010	29,14	32,35	30,75	27,88
12/28/2010	27,75	27,61	26,23	28,97
12/29/2010	32,64	29,80	30,69	30,53
12/30/2010	31,94	31,73	30,33	29,71
12/31/2010	31,59	30,94	31,79	31,60
Tanggal	Curug (°C)	Tangerang (°C)	Citeko (°C)	Dermaga (°C)
1/31/2009	26.64	26.22	28.73	27.60
2/1/2009	27.57	27.26	27.14	30.37
2/2/2009	27.58	26.12	27.86	28.28
2/3/2009	29.98	27.39	32.44	27.68
2/4/2009	26.97	28.40	22.37	24.70
2/5/2009	25.36	25.76	25.30	27.41
2/6/2009	28.96	30.20	26.25	26.99
2/7/2009	31.47	27.74	29.43	29.19
2/8/2009	25.12	27.50	22.96	21.20
2/9/2009	26.85	28.35	27.77	28.15
2/10/2009	28.56	28.79	30.52	31.70
2/11/2009	28.60	29.30	27.30	27.51
⋮	⋮	⋮	⋮	⋮
12/25/2010	32.28	30.56	27.08	31.91
12/26/2010	31.89	30.29	32.80	28.09
12/27/2010	31.13	29.15	28.18	32.42
12/28/2010	28.17	24.48	25.53	32.62
12/29/2010	28.53	33.88	30.00	32.23
12/30/2010	30.67	29.06	31.94	31.77
12/31/2010	30.82	30.37	32.61	29.53

Lampiran 52. Prakiraan Suhu Minimum GOP

Tanggal	Kemayoran (°C)	Priok (°C)	Cengkareng (°C)	Pd. Betung (°C)
1/31/2009	24,11	23,62	24,22	23,66
2/1/2009	22,87	21,72	23,23	24,18
2/2/2009	22,44	23,86	24,46	26,12
2/3/2009	22,64	23,81	24,16	26,35
2/4/2009	23,08	25,63	22,55	22,16
2/5/2009	22,98	23,49	22,95	23,30
2/6/2009	23,59	23,89	24,09	23,73
2/7/2009	21,84	22,38	23,14	23,31
2/8/2009	23,44	20,87	20,25	20,20
2/9/2009	23,66	21,40	21,67	22,56
2/10/2009	23,99	25,11	24,71	22,44
2/11/2009	23,24	23,91	20,81	23,72
⋮	⋮	⋮	⋮	⋮
12/25/2010	24,13	22,79	24,20	24,38
12/26/2010	22,85	22,27	23,24	22,53
12/27/2010	23,24	20,18	24,17	23,33
12/28/2010	21,62	20,51	22,73	21,96
12/29/2010	22,27	23,73	22,27	25,30
12/30/2010	22,86	21,64	23,43	22,86
12/31/2010	24,68	24,54	26,06	24,10
Tanggal	Curug (°C)	Tangerang (°C)	Citeko (°C)	Dermaga (°C)
1/31/2009	25,69	24,25	23,68	25,11
2/1/2009	24,47	26,03	24,25	25,58
2/2/2009	22,61	21,09	22,74	24,75
2/3/2009	25,41	23,88	24,42	24,75
2/4/2009	22,33	22,42	21,86	20,96
2/5/2009	24,36	23,07	23,21	23,66
2/6/2009	23,89	24,00	23,44	21,91
2/7/2009	22,45	21,62	23,97	23,32
2/8/2009	23,57	24,61	23,80	24,12
2/9/2009	25,71	22,98	24,12	22,79
2/10/2009	23,45	23,98	26,38	25,94
2/11/2009	22,53	25,89	20,35	23,42
⋮	⋮	⋮	⋮	⋮
12/25/2010	24,10	22,80	25,65	23,31
12/26/2010	23,00	22,11	21,78	21,35
12/27/2010	21,49	23,38	22,47	20,00
12/28/2010	22,36	20,42	20,16	20,80
12/29/2010	23,10	23,01	22,95	21,97
12/30/2010	24,69	24,65	20,70	21,23
12/31/2010	26,42	24,74	25,55	25,62

Lampiran 53. Indikator Keباikan Prakiraan Tiap 8 Stamet untuk Training 30 Hari

Suhu Udara	Stamet	RMSE (°C)			CRPS	
		NWP	Mean Ensemble	BMA	Raw Ensemble	BMA
T _{MAKS}	Cengkareng	2,323	0,996	0,994	0,668	0,536
	Citeko	3,955	1,088	1,068	0,787	0,604
	Curug	2,722	1,108	1,069	0,749	0,587
	Dermaga	1,657	0,955	0,950	0,653	0,517
	Kemayoran	2,626	1,074	1,082	0,750	0,598
	Pd. Betung	3,305	1,126	1,103	0,778	0,605
	Tangerang	2,861	1,049	1,051	0,701	0,568
	Priok	2,508	1,067	1,103	0,721	0,589
T _{MIN}	Cengkareng	1,173	0,736	0,750	0,516	0,407
	Citeko	5,367	0,648	0,668	0,456	0,365
	Curug	0,977	0,660	0,683	0,479	0,378
	Dermaga	1,657	0,784	0,777	0,566	0,431
	Kemayoran	2,171	0,810	0,838	0,614	0,476
	Pd. Betung	1,188	0,822	0,810	0,581	0,446
	Tangerang	1,371	1,131	1,164	0,781	0,626
	Priok	2,174	0,848	0,862	0,624	0,482
Suhu Udara	Stamet	Coverage (%)				
		Raw Ensemble	BMA			
T _{MAKS}	Cengkareng	18,00	48,67			
	Citeko	12,54	47,49			
	Curug	18,14	50,00			
	Dermaga	20,65	49,41			
	Kemayoran	15,34	50,88			
	Pd. Betung	16,37	50,30			
	Tangerang	16,08	49,56			
	Priok	13,27	51,92			
T _{MIN}	Cengkareng	21,53	49,56			
	Citeko	8,55	47,34			
	Curug	7,08	50,00			
	Dermaga	6,77	49,26			
	Kemayoran	12,09	43,36			
	Pd. Betung	8,26	47,34			
	Tangerang	9,14	54,28			
	Priok	7,08	44,98			

Lampiran 54. Kriteria Prakiraan Cuaca Berdasarkan RMSE

a) BMA

Suhu Udara	Stamet	RMSE(°C)		
		NWP	BMA	Kriteria Nilai RMSE
T_{MAKS}	Cengkareng	2,323	0,994	Sedang
	Citeko	3,955	1,068	Sedang
	Curug	2,722	1,069	Sedang
	Dermaga	1,657	0,950	Sedang
	Kemayoran	2,626	1,082	Sedang
	Pd. Betung	3,305	1,103	Sedang
	Tangerang	2,861	1,051	Sedang
	Priok	2,508	1,103	Sedang
T_{MIN}	Cengkareng	1,173	0,750	Baik
	Citeko	5,367	0,668	Baik
	Curug	0,977	0,683	Baik
	Dermaga	1,657	0,777	Baik
	Kemayoran	2,171	0,838	Sedang
	Pd. Betung	1,188	0,810	Sedang
	Tangerang	1,371	1,164	Sedang
	Priok	2,174	0,862	Sedang

b) GOP

	Dengan stamet Citeko	Kriteria	Tanpa stamet Citeko	Kriteria
	RMSE (°C)		RMSE (°C)	
T_{MAKS}	3,07	Buruk	1,92	Buruk
T_{MIN}	2,67	Buruk	1,86	Buruk

Lampiran 55. Syntax Program

a. Syntax untuk Reduksi Dimensi Parameter NWP dengan PCA

```
pca1<-read.csv("E:CCAM/Dermaga/parameter/dpsdt.csv",header=T)
pca=scale(pca1)
kovarian<-cov(pca)
eigenvalue<-eigen(kovarian)$value
eigenvalue
fit_pca<-princomp(pca,cor=FALSE)
sdev<-fit_pca$sdev
sumvar<-sum(eigenvalue)
p<-ncol(pca)
var <- matrix(c(0),p,1)
cumvar <- matrix(c(0),p,1)
for(i in 1:p){
  var[i] <- eigenvalue[i]/sumvar
  if (i == 1) {cumvar[i] <- var[i]}
  else
    cumvar[i] <- var[i] + cumvar[i-1]
}
write.csv(cbind(eigenvalue,sdev,var,cumvar),"E:CCAM/Dermaga/olah_pca/eigenvalue_dpsdt.csv")
loadings<-loadings(fit_pca)
write.csv(cbind(loadings),"E:CCAM/Dermaga/olah_pca/koefisien_dpsdt.csv")
score<-fit_pca$scores
write.csv(cbind(score),"E:CCAM/Dermaga/olah_pca/score_dpsdt.csv")
```

Ket.: Syntax di atas hanya untuk parameter dpsdt stamet Dermaga

b. Syntax untuk Menghasilkan Prakiraan Anggota Ensemble

```
library(pls)
library(plsdepot)
library(MASS)
pca<-read.csv("E:CCAM/Dermaga/pca_drmg.csv",header=T)
tr1<-pca[,1:44]
x1=tr1[,1:41]
y=tr1[,42:44]
x=scale(x1)
tr=cbind(x,y)
#mencari komponen optimal Tmaks PLS1#
#RMSEP terendah#
pls.tmaks<-
mvr(Tmaks~PC.dpsdt+PC.mixr1+PC.mixr2+PC.mixr4+PC1.omega1+PC2.omega1+PC1.omega2+PC2.omega2+PC1.omega4+PC2.omega4+PC.pblh+PC.ps+PC.psl+PC1.qgscrn+PC2.qgscrn+PC1.rh1+PC2.rh1+PC.rh2+PC.rh4+PC.rnd+PC.temp1+PC.temp2+PC.temp4+PC.tmaxscr+PC.tminscr+PC.tpan+PC.tscrn+PC.u1+PC.u2+PC.u4+PC1.ustar+PC2.ustar+PC1.v1+PC2.v1+PC1.v2+PC2.v2+PC.v4+PC.zg1+PC.zg2+PC1.zg4+PC2.zg4,data=as.data.frame(tr),ncomp=41,method=pls.options()$plsr)
summary(crossval(pls.tmaks))
```

```

#mencari komponen optimal Tmin PLS1#
#RMSEP terendah#
pls.tmin<-
mvr(Tmin~PC.dpsdt+PC.mixr1+PC.mixr2+PC.mixr4+PC1.omega1+PC2.omega1+PC1.o
mega2+PC2.omega2+PC1.omega4+PC2.omega4+PC.pblh+PC.ps+PC.psl+PC1.qgscrn+P
C2.qgscrn+PC1.rh1+PC2.rh1+PC.rh2+PC.rh4+PC.rnd+PC.temp1+PC.temp2+PC.temp4+
PC.tmaxscr+PC.tminscr+PC.tpan+PC.tscrn+PC.u1+PC.u2+PC.u4+PC1.ustar+PC2.ustar+
PC1.v1+PC2.v1+PC1.v2+PC2.v2+PC.v4+PC.zg1+PC.zg2+PC1.zg4+PC2.zg4,data=as.dat
a.frame(tr),ncomp=41,method=pls.options())$plsr)
summary(crossval(pls.tmin))
#mencari komponen optimal Tmaks PCR#
#berdasarkan kumulatif varians minimal 80%#
pcr.tmaks<-
mvr(Tmaks~PC.dpsdt+PC.mixr1+PC.mixr2+PC.mixr4+PC1.omega1+PC2.omega1+PC1.
omega2+PC2.omega2+PC1.omega4+PC2.omega4+PC.pblh+PC.ps+PC.psl+PC1.qgscrn+
PC2.qgscrn+PC1.rh1+PC2.rh1+PC.rh2+PC.rh4+PC.rnd+PC.temp1+PC.temp2+PC.temp4
+PC.tmaxscr+PC.tminscr+PC.tpan+PC.tscrn+PC.u1+PC.u2+PC.u4+PC1.ustar+PC2.ustar
+PC1.v1+PC2.v1+PC1.v2+PC2.v2+PC.v4+PC.zg1+PC.zg2+PC1.zg4+PC2.zg4,data=as.d
ata.frame(tr),ncomp=41,method=pls.options())$pcr)
summary(crossval(pcr.tmaks))
#mencari komponen optimal Tmin PCR#
#berdasarkan kumulatif varians minimal 80%#
pcr.tmin<-
mvr(Tmin~PC.dpsdt+PC.mixr1+PC.mixr2+PC.mixr4+PC1.omega1+PC2.omega1+PC1.o
mega2+PC2.omega2+PC1.omega4+PC2.omega4+PC.pblh+PC.ps+PC.psl+PC1.qgscrn+P
C2.qgscrn+PC1.rh1+PC2.rh1+PC.rh2+PC.rh4+PC.rnd+PC.temp1+PC.temp2+PC.temp4+
PC.tmaxscr+PC.tminscr+PC.tpan+PC.tscrn+PC.u1+PC.u2+PC.u4+PC1.ustar+PC2.ustar+
PC1.v1+PC2.v1+PC1.v2+PC2.v2+PC.v4+PC.zg1+PC.zg2+PC1.zg4+PC2.zg4,data=as.dat
a.frame(tr),ncomp=41,method=pls.options())$pcr)
summary(crossval(pcr.tmin))
#mencari penalti optimal Tmaks Ridge#
ridge.tmaks<-
lm.ridge(Tmaks~PC.dpsdt+PC.mixr1+PC.mixr2+PC.mixr4+PC1.omega1+PC2.omega1+P
C1.omega2+PC2.omega2+PC1.omega4+PC2.omega4+PC.pblh+PC.ps+PC.psl+PC1.qgscr
n+PC2.qgscrn+PC1.rh1+PC2.rh1+PC.rh2+PC.rh4+PC.rnd+PC.temp1+PC.temp2+PC.tem
p4+PC.tmaxscr+PC.tminscr+PC.tpan+PC.tscrn+PC.u1+PC.u2+PC.u4+PC1.ustar+PC2.ust
ar+PC1.v1+PC2.v1+PC1.v2+PC2.v2+PC.v4+PC.zg1+PC.zg2+PC1.zg4+PC2.zg4,data=tr,l
ambda=seq(0,10,.001))
plot(ridge.tmaks)
#konstan setelah 9#
#mencari penalti optimal Tmin Ridge#
ridge.tmin<-
lm.ridge(Tmin~PC.dpsdt+PC.mixr1+PC.mixr2+PC.mixr4+PC1.omega1+PC2.omega1+PC
1.omega2+PC2.omega2+PC1.omega4+PC2.omega4+PC.pblh+PC.ps+PC.psl+PC1.qgscrn
+PC2.qgscrn+PC1.rh1+PC2.rh1+PC.rh2+PC.rh4+PC.rnd+PC.temp1+PC.temp2+
PC.temp4+PC.tmaxscr+PC.tminscr+PC.tpan+PC.tscrn+PC.u1+PC.u2+PC.u4+PC1.ustar+
PC2.ustar+PC1.v1+PC2.v1+PC1.v2+PC2.v2+PC.v4+PC.zg1+PC.zg2+
PC1.zg4+PC2.zg4,data=tr,lambda = seq(0,10,.001))
plot(ridge.tmin) #konstan setelah 9#

```

```

#PLS1#
t.maks<-pca[,42]
t.min<-pca[,43]
Xtr<-scale(pca[,1:41])
dmg1.tr=plsreg1(Xtr,t.maks,comps=16)
dmg2.tr=plsreg1(Xtr,t.min,comps=3)
Ytr1.hat=as.matrix(Xtr)%*(dmg1.tr$std.coefs)
Ytr2.hat=as.matrix(Xtr)%*(dmg2.tr$std.coefs)
obs<-read.csv("E:CCAM/Dermaga/obs_drmg.csv",header=T)
a=vector(mode="numeric",length=2)
b=vector(mode="numeric",length=2)
for (i in 1:2){
a[i]=mean(obs[,i])
b[i]=sd(obs[,i])
}
PLS1.Tmaks=(Ytr1.hat*b[1])+a[1]
PLS1.Tmin=(Ytr2.hat*b[2])+a[2]
y1.hat=cbind(PLS1.Tmaks,PLS1.Tmin)
#PCR#
tmax.tr=pcr(Tmaks~PC.dpsdt+PC.mixr1+PC.mixr2+PC.mixr4+PC1.omega1+PC2.omega1+PC1.omega2+PC2.omega2+PC1.omega4+PC2.omega4+PC.pblh+PC.ps+PC.psl+PC1.qgscrn+PC2.qgscrn+PC1.rh1+PC2.rh1+PC.rh2+PC.rh4+PC.rnd+PC.temp1+PC.temp2+PC.temp4+PC.tmaxscr+PC.tminscr+PC.tpan+PC.tscrn+PC.u1+PC.u2+PC.u4+PC1.ustar+PC2.ustar+PC1.v1+PC2.v1+PC1.v2+PC2.v2+PC.v4+PC.zg1+PC.zg2+PC1.zg4+PC2.zg4,8,data=tr)
tmin.tr=pcr(Tmin~PC.dpsdt+PC.mixr1+PC.mixr2+PC.mixr4+PC1.omega1+PC2.omega1+PC1.omega2+PC2.omega2+PC1.omega4+PC2.omega4+PC.pblh+PC.ps+PC.psl+PC1.qgscrn+PC2.qgscrn+PC1.rh1+PC2.rh1+PC.rh2+PC.rh4+PC.rnd+PC.temp1+PC.temp2+PC.temp4+PC.tmaxscr+PC.tminscr+PC.tpan+PC.tscrn+PC.u1+PC.u2+PC.u4+PC1.ustar+PC2.ustar+PC1.v1+PC2.v1+PC1.v2+PC2.v2+PC.v4+PC.zg1+PC.zg2+PC1.zg4+PC2.zg4,8,data=tr)
tmax.tr.fit=tmax.tr$fitted.values[,8]
tmin.tr.fit=tmin.tr$fitted.values[,8]
obs<-read.csv("E:CCAM/Dermaga/obs_drmg.csv",header=T)
c=vector(mode="numeric",length=2)
d=vector(mode="numeric",length=2)
for (i in 1:2){
c[i]=mean(obs[,i])
d[i]=sd(obs[,i])
}
PCR.Tmaks=(tmax.tr.fit*b[1])+a[1]
PCR.Tmin=(tmin.tr.fit*b[2])+a[2]
y2.hat=cbind(PCR.Tmaks,PCR.Tmin)
#ridge#
ridge<-
lm.ridge(Tmaks~PC.dpsdt+PC.mixr1+PC.mixr2+PC.mixr4+PC1.omega1+PC2.omega1+PC1.omega2+PC2.omega2+PC1.omega4+PC2.omega4+PC.pblh+PC.ps+PC.psl+PC1.qgscrn+PC2.qgscrn+PC1.rh1+PC2.rh1+PC.rh2+PC.rh4+PC.rnd+PC.temp1+PC.temp2+PC.temp4+PC.tmaxscr+PC.tminscr+PC.tpan+PC.tscrn+PC.u1+PC.u2+PC.u4+PC1.ustar+PC2.ustar+PC1.v1+PC2.v1+PC1.v2+PC2.v2+PC.v4+PC.zg1+PC.zg2+PC1.zg4+PC2.zg4,data=tr,lambda=9)

```

```

ridge1<
lm.ridge(Tmin~PC.dpsdt+PC.mixr1+PC.mixr2+PC.mixr4+PC1.omega1+PC2.omega1+PC1.
omega2+PC2.omega2+PC1.omega4+PC2.omega4+PC.pblh+PC.ps+PC.psl+PC1.qgscrn+PC
2.qgscrn+PC1.rh1+PC2.rh1+PC.rh2+PC.rh4+PC.rnd+PC.temp1+PC.temp2+
PC.temp4+PC.tmaxscr+PC.tminscr+PC.tpan+PC.tscrn+PC.u1+PC.u2+PC.u4+PC1.ustar+PC
2.ustar+PC1.v1+PC2.v1+PC1.v2+PC2.v2+PC.v4+PC.zg1+PC.zg2+PC1.zg4+PC2.zg4,data=t
r,lambda=9)
ridge.hat<-coef(ridge)[2]*tr[,1] +
coef(ridge)[3]*tr[,2] + coef(ridge)[4]*tr[,3] + coef(ridge)[5]*tr[,4]+
coef(ridge)[6]*tr[,5] + coef(ridge)[7]*tr[,6] + coef(ridge)[8]*tr[,7]+
coef(ridge)[9]*tr[,8] + coef(ridge)[10]*tr[,9] + coef(ridge)[11]*tr[,10]+
coef(ridge)[12]*tr[,11]+coef(ridge)[13]*tr[,12]+coef(ridge)[14]*tr[,13]+
coef(ridge)[15]*tr[,14]+coef(ridge)[16]*tr[,15]+coef(ridge)[17]*tr[,16]+
coef(ridge)[18]*tr[,17]+coef(ridge)[19]*tr[,18]+coef(ridge)[20]*tr[,19]+
coef(ridge)[21]*tr[,20]+coef(ridge)[22]*tr[,21]+coef(ridge)[23]*tr[,22]+
coef(ridge)[24]*tr[,23]+coef(ridge)[25]*tr[,24]+coef(ridge)[26]*tr[,25]+
coef(ridge)[27]*tr[,26]+coef(ridge)[28]*tr[,27]+coef(ridge)[29]*tr[,28]+
coef(ridge)[30]*tr[,29]+coef(ridge)[31]*tr[,30]+coef(ridge)[32]*tr[,31]+
coef(ridge)[33]*tr[,32]+coef(ridge)[34]*tr[,33]+coef(ridge)[35]*tr[,34]+
coef(ridge)[36]*tr[,35]+coef(ridge)[37]*tr[,36]+coef(ridge)[38]*tr[,37]+
coef(ridge)[39]*tr[,38]+coef(ridge)[40]*tr[,39]+coef(ridge)[41]*tr[,40]+
coef(ridge)[42]*tr[,41]
ridge1.hat<-coef(ridge1)[2]*tr[,1] +
coef(ridge1)[3]*tr[,2] + coef(ridge1)[4]*tr[,3] + coef(ridge1)[5]*tr[,4]+
coef(ridge1)[6]*tr[,5] + coef(ridge1)[7]*tr[,6] + coef(ridge1)[8]*tr[,7]+
coef(ridge1)[9]*tr[,8] + coef(ridge1)[10]*tr[,9] + coef(ridge1)[11]*tr[,10]+
coef(ridge1)[12]*tr[,11]+coef(ridge1)[13]*tr[,12]+coef(ridge1)[14]*tr[,13]+
coef(ridge1)[15]*tr[,14]+coef(ridge1)[16]*tr[,15]+coef(ridge1)[17]*tr[,16]+
coef(ridge1)[18]*tr[,17]+coef(ridge1)[19]*tr[,18]+coef(ridge1)[20]*tr[,19]+
coef(ridge1)[21]*tr[,20]+coef(ridge1)[22]*tr[,21]+coef(ridge1)[23]*tr[,22]+
coef(ridge1)[24]*tr[,23]+coef(ridge1)[25]*tr[,24]+coef(ridge1)[26]*tr[,25]+
coef(ridge1)[27]*tr[,26]+coef(ridge1)[28]*tr[,27]+coef(ridge1)[29]*tr[,28]+
coef(ridge1)[30]*tr[,29]+coef(ridge1)[31]*tr[,30]+coef(ridge1)[32]*tr[,31]+
coef(ridge1)[33]*tr[,32]+coef(ridge1)[34]*tr[,33]+coef(ridge1)[35]*tr[,34]+
coef(ridge1)[36]*tr[,35]+coef(ridge1)[37]*tr[,36]+coef(ridge1)[38]*tr[,37]+
coef(ridge1)[39]*tr[,38]+coef(ridge1)[40]*tr[,39]+coef(ridge1)[41]*tr[,40]+
coef(ridge1)[42]*tr[,41]
e=mean(obs[,1])
f=sd(obs[,1])
Ridge.tmaks=ridge.hat*f+e
g=mean(obs[,2])
h=sd(obs[,2])
Ridge.tmin=ridge1.hat*h+g
y3.hat=cbind(Ridge.tmaks,Ridge.tmin)
#kompilasi data#
ens=cbind(y1.hat,y2.hat,y3.hat,obs[,-3])
write.csv(ens,"E:CCAM/Dermaga/ensemble_drmg.csv")

```

c. Syntax BMA untuk Suhu Maksimum Stamet Dermaga

```
#BMA dengan n=708 hari dan training=30#
library(ensembleBMA)
ensBMAtest=read.csv("E:CCAM/Dermaga/BMA/ens_BMA (drmg).csv",header=T)
data=ensBMAtest
T=30
n=3
tgl=data$vdate
start=which(data$vdate==tgl)
jmlh=length(start)
test=jmlh-T
data1=data[,4:6]
y1=data[,3]
x=matrix(c(0),test,n)
y=vector(mode="numeric",length=test)
x=as.matrix(data1[(T+1):jmlh,])
y=y1[(T+1):jmlh]
ensMemNames = c("PLS","PCR","Ridge")
obs = paste("Tmaks","obs", sep = ".")
ens = paste("Tmaks", ensMemNames, sep = ".")
BMADData = ensembleData(forecasts = data[,ens],dates = data[,vdate],observations =
data[,obs],station = data[,station],forecastHour = 24,initializationTime = "00")
BMAfit=ensembleBMA(BMADData,model="normal",trainingDays=T)
miss=c(186,192,196,198,199,211,217,218,235,237,259,271,272,273,380,385,406,458,524,
586,653,722,731)
aa=miss-T
aa1=3*aa
aa2=aa1-1
aa3=aa1-2
a=sort(c(aa3,aa2,aa1))
bobot1=as.vector(BMAfit$weights)
bobot=bobot1[-a]
w1=vector(mode="numeric",length=test)
w2=vector(mode="numeric",length=test)
w3=vector(mode="numeric",length=test)
k=1
for (l in 1:test){
w1[l]=bobot[k]
w2[l]=bobot[k+1]
w3[l]=bobot[k+2]
k=k+3
}
aa4=6*aa
aa5=aa4-1
aa6=aa4-2
aa7=aa4-3
aa8=aa4-4
aa9=aa4-5
```

```

az=sort(c(aa4,aa5,aa6,aa7,aa8,aa9))
koeff=BMAfit$biasCoefs
koef=as.matrix(koeff)
koef1=koef[-az]
i=1
a1=vector(mode="numeric",length=test)
b1=vector(mode="numeric",length=test)
a2=vector(mode="numeric",length=test)
b2=vector(mode="numeric",length=test)
a3=vector(mode="numeric",length=test)
b3=vector(mode="numeric",length=test)
for (j in 1:test){
a1[j]=koef1[i]
b1[j]=koef1[1+i]
a2[j]=koef1[2+i]
b2[j]=koef1[3+i]
a3[j]=koef1[4+i]
b3[j]=koef1[5+i]
i=i+6
}
sdev1=as.vector(BMAfit$sdev)
sdev=sdev1[-aa]
obs=y
fore1=as.vector(a1+b1*(x[,1]))
fore2=as.vector(a2+b2*(x[,2]))
fore3=as.vector(a3+b3*(x[,3]))
mean_BMA=w1*fore1+w2*fore2+w3*fore3
mean_ens=as.vector((x[,1]+x[,2]+x[,3])/n)
var_BMA=(w1*(fore1-mean_BMA)^2+w2*(fore2-mean_BMA)^2+w3*(fore3-
mean_BMA)^2)+sdev
nilai_CRPS=CRPS(BMAfit,BMADData)
res_PLS=vector(length=test)
res_PCR=vector(length=test)
res_Ridge=vector(length=test)
res_BMA=vector(length=test)
for (i in 1:test){
res_PLS[i]=(y[i]-x[i,1])^2
res1=as.vector(res_PLS)
res_PCR[i]=(y[i]-x[i,2])^2
res2=as.vector(res_PCR)
res_Ridge[i]=(y[i]-x[i,3])^2
res3=as.vector(res_Ridge)
res_BMA[i]=(y[i]-mean_BMA[i])^2
res4=as.vector(res_BMA)
}
RMSE_PLS=sqrt(sum(res1)/test)
RMSE_PCR=sqrt(sum(res2)/test)
RMSE_Ridge=sqrt(sum(res3)/test)
RMSE_BMA=sqrt(sum(res4)/test)

```

```

RMSE=list(RMSE_PLS=RMSE_PLS,RMSE_PCR=RMSE_PCR,RMSE_Ridge=RMSE_
Ridge,RMSE_BMA=RMSE_BMA)
l=mean_BMA-1.96*sqrt(var_BMA)
u=mean_BMA+1.96*sqrt(var_BMA)
pls=vector(mode="numeric",length=test)
pcr=vector(mode="numeric",length=test)
ridge=vector(mode="numeric",length=test)
c4=vector(mode="numeric",length=test)
bma=matrix(0,test,3)
for (i in 1:test){
s=100000
pls[i]=sample(rnorm(s,fore1[i],sdev[i]),1)
pcr[i]=sample(rnorm(s,fore2[i],sdev[i]),1)
ridge[i]=sample(rnorm(s,fore3[i],sdev[i]),1)
bma[i,]=cbind(pls[i],pcr[i],ridge[i])
if (y[i]<min(bma[i,])|y[i]>max(bma[i,])){c4[i]=0}
else c4[i]=1
}
coverage=(sum(c4)/test)*100
RMSE
nilai_CRPS
coverage
library(SpecsVerification)
rank.hist1=Rankhist(bma,y)
PlotRankhist(rank.hist1,mode="prob.paper")
write.csv(cbind(w1,w2,w3),"E:CCAM/Dermaga/BMA/Tmaks/bobot_30.csv")
write.csv(cbind(a1,b1,a2,b2,a3,b3),"E:CCAM/Dermaga/BMA/Tmaks/koefisien_30.csv")
write.csv(cbind(x,mean_ens,mean_BMA,obs),"E:CCAM/Dermaga/BMA/Tmaks/forecast_
30.csv")
#membuat perbandingan PDF#
s=100000
s1=rnorm(s,fore1[1],sdev[1])
s2=rnorm(s,fore2[1],sdev[1])
s3=rnorm(s,fore3[1],sdev[1])
d1=density(s1)
d2=density(s2)
d3=density(s3)
mix=rnorm(s,mean_BMA[1],sqrt(var_BMA[1]))
dmix=density(mix)
min=min(mix,mix-2)
max=max(mix,mix+2)
plot(d1,xlim=c(min,max),main="",col="blue",lwd=2)
par(new=TRUE)
plot(d2,xlim=c(min,max),axes=F,xlab="",ylab="",main="",col="orange",lwd=2)
par(new=TRUE)
plot(d3,xlim=c(min,max),axes=F,xlab="",ylab="",main="",col="darkgreen",lwd=2)
par(new=TRUE)
plot(dmix,xlim=c(min,max),axes=F,xlab="",ylab="",main="",col="red",lwd=5)

```



```

lower=mean_BMA[1]-1.96*sqrt(var_BMA[1])
upper=mean_BMA[1]+1.96*sqrt(var_BMA[1])
abline(v=y[1],col="black")
abline(v=lower,col="black",lty=2)
abline(v=upper,col="black",lty=2)
lines(x=c(x[1,1],x[1,2],x[1,3]),y=c(0.1,0.1,0.1),col="black",type="o",xlab="",ylab="",mai
n="")
ind=c("blue","orange","darkgreen","red","black","black")
legend("topright",legend=c("PLS","PCR","Ridge","BMA","Obs.,"95% CI
BMA"),lty=c(1,1,1,1,1,3),col=c(ind),ncol=1,text.font=4)

```

d. Syntax GOP

```

library(fields)
library(RandomFields)
library(ProbForecastGOP)
library(gstat)
library(SpecsVerification)
library(automap)
gop.tmin=read.csv("E:CCAM/GOP/gop_tmin.csv",header=T)
koord=read.csv("E:CCAM/GOP/tmaks_utm.csv",header=T)
utm=koord[,-3]
train=30
day <- gop.tmin$date.obs[1:(8*train)]
id <- gop.tmin$id.stat[1:8]
obs1 <- gop.tmin$obs[1:(8*train)]
forecast <- gop.tmin$forecast[1:(8*train)]
col1=cbind(id,obs1)
col2=cbind(id,forecast)
obs=aggregate(col1[,2],list(col1[,1]),mean)
fore=aggregate(col2[,2],list(col2[,1]),mean)
obs=obs[,-1]
fore=fore[,-1]
data=cbind(utm,obs,fore)
coordinates(data) =~ x+y
variog= autofitVariogram(obs~fore,data,model="Exp")
param=variog$var_model
sill=param$psill
range=(param$range[2])/1000
gop.tmin=read.csv("E:CCAM/GOP/gop_tmin.csv",header=T)
train=30
day <- gop.tmin$date.obs[1:(8*train)]
id <- gop.tmin$id.stat[1:(8*train)]
coord1 <- gop.tmin$lon.stat[1:(8*train)]
coord2 <- gop.tmin$lat.stat[1:(8*train)]
obs <- gop.tmin$obs[1:(8*train)]
forecast <- gop.tmin$forecast[1:(8*train)]
lt=length(gop.tmin$obs)/8
ntest=lt-train

```

```

lm.tmin <- lm(obs ~ forecast)
lm.tmin$coeff
variogram <-
Emp.variog(day=day,obs=obs,forecast=forecast,id=id,coord1=coord1,coord2=coord2,
cut.points=seq(0,100,by=1),max.dist=NULL,nbins=NULL)
plot(variogram$bin.midpoints,variogram$empir.variog,xlab="Jarak(km)",ylab="Semi-
varians")
lines(variogram$bin.midpoints,linesmodel(distance=variogram$bin.midpoints,
variog.model="exponential",param=c(sill[1],sill[2],range)))
nsim=99
a=array(rep(0,8*ntest*nsim),dim=c(8,ntest,nsim))
for (z in 1:nsim){
for (i in 1:ntest){
model <- RMexp(var=sill[2],scale=range) + RMnugget(var=sill[1])
simu <- RFsimulate(model,x=coord1[1:8],y=coord2[1:8])
a[,i,z]=simu$variable1
}
}
j=1
z=1
s=matrix(c(0),(ntest*8),nsim)
for (z in 1:nsim){
for (i in 1:ntest){
k=j+1
l=j+2
m=j+3
n=j+4
o=j+5
p=j+6
q=j+7
s[j,z]=a[1,i,z]
s[k,z]=a[2,i,z]
s[l,z]=a[3,i,z]
s[m,z]=a[4,i,z]
s[n,z]=a[5,i,z]
s[o,z]=a[6,i,z]
s[p,z]=a[7,i,z]
s[q,z]=a[8,i,z]
j=j+8
}
j=1
z=z+1
}
obs_test <- gop.tmin$obs[-(1:(8*train))]
fore_test <- gop.tmin$forecast[-(1:(8*train))]
b0=as.vector(lm.tmin$coeff[1])
b1=as.vector(lm.tmin$coeff[2])
fore_GOP=matrix(c(0),(ntest*8),nsim)
for (j in 1:nsim){

```

```

fore_GOP[,j]=(b0+b1*fore_test)+s[,j]
}
res=matrix(c(0),(ntest*8),nsim)
for (j in 1:nsim){
res[,j]=(obs_test-fore_GOP[,j])^2
}
sta=c(seq(from=1,to=8,by=1))
col=factor(rep(sta,ntest))
resi=cbind(col,res)
MSE_GOP=aggregate(resi[,2:(nsim+1)],list(resi[,1]),mean)
RMSE_GOP=vector(mode="numeric",length=nsim)
for (i in 1:nsim){
RMSE_GOP[i]=mean(sqrt(MSE_GOP[,i+1]))
}
res_NWP=(obs_test-fore_test)^2
resi_NWP=cbind(col,res_NWP)
MSE_NWP=aggregate(resi_NWP[,2],list(resi_NWP[,1]),mean)
RMSE_NWP=mean(sqrt(MSE_NWP[,2]))
RMSE_NWP
min(RMSE_GOP)
select=which.min(RMSE_GOP)
forecastGOP=fore_GOP[,select]
v=vector(mode="numeric",length=(ntest*8))
u=vector(mode="numeric",length=(ntest*8))
c1=vector(mode="numeric",length=(ntest*8))
for (i in 1:(ntest*8)){
v[i]=quantile(fore_GOP[i,],probs=95/100)
u[i]=quantile(fore_GOP[i,],probs=5/100)
if (obs_test[i]<u[i]|obs_test[i]>v[i]){c1[i]=0}
else c1[i]=1
}
coverage=(sum(c1)/(ntest*8))*100
coverage
nilai_CRPS=mean(EnsCrps(fore_GOP,obs_test))
nilai_CRPS
comp=cbind(gop.tmin$date.obs[-(1:(8*train))],gop.tmin$id.stat[-
(1:(8*train))],gop.tmin$lon.stat[-(1:(8*train))],gop.tmin$lat.stat[-
(1:(8*train))],obs_test,fore_test,forecastGOP,v,u)
write.csv(comp,"E:CCAM/GOP/suhu/gop_tmin-30hari.csv")

```

(Halaman ini sengaja dikosongkan)

BIODATA PENULIS



Muhammad Luthfi S. lahir di Palangka Raya, Kalimantan Tengah pada tanggal 31 Maret 1993. Penulis merupakan anak kedua dari 2 bersaudara, dari pasangan Bapak Setiarno dan Ibu Maimunah. Penulis menempuh jenjang pendidikan formal mulai dari TK Perwanida, SDN Menteng 6 P.Raya, MTsN 1 Model P. Raya, SMAN 2 P. Raya, S1 Statistika ITS, dan diterima sebagai mahasiswa S2 Statistika ITS pada tahun 2016 untuk Batch 2 2015 dengan NRP 1315201203 melalui Jalur Mandiri. Selama menjadi mahasiswa pascasarjana, penulis pernah menjadi asisten dosen mata kuliah Biostatistika pada Departemen Biologi dan beberapa kali menjadi *freelance* analis data untuk salah satu NGO di Surabaya. Bagi pembaca yang memiliki saran, kritik, masukan atau ingin berdiskusi dengan penulis terkait konten atau materi pada Tesis ini, dapat menghubungi *email* luthfi2011@yahoo.co.id.